

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Extrakce plodového elektrokardiogramu metodami soft computingu

Fetal ECG Extraction Based on Soft Computing

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Studenti: **Bc. Hana Škutová**
Studijní program: **N2649 Elektrotechnika**
Studijní obor: **3901T009 Biomedicínské inženýrství**
Téma: **Extrakce plodového elektrokardiogramu metodami soft computingu**
Fetal ECG Extraction Based on Soft Computing
Jazyk vypracování: **čeština**

Zásady pro vypracování:

Tématem diplomové práce je studie vybraných soft-computingových metod, které je možno aplikovat v oblasti zpracování plodového elektrocardiogramu. Práce se věnuje popisu výpočetních postupů, jejichž společně jmenovatele je možno klasifikovat jako odliš od klasického modelování, založeného na analytických metodách, booleovské logice, ostré klasifikaci a deterministickým probíháváním (tj. fuzzy logika, umělé neuronové sítě a genetické algoritmy). Cílem diplomové práce je návrh a realizace systému pro zpracování plodového elektrokardiogramu za použití soft-computingových metod. Nezbytným krokem je ověření funkčnosti těchto metod na syntetických i reálných datech z klinické praxe.

Postup řešení

1. Literární rešerše současného stavu problematiky extrakce plodového elektrokardiogramu metodami soft computingu.
2. Klasifikace a popis vybraných soft-computingových metod (např. umělé neuronové sítě, fuzzy logika, fuzzy-neuronové sítě (např. ANFIS), genetické algoritmy, apod.).
3. Návrh a softwarová realizace systému pro extrakci plodového elektrokardiogramu s využitím vybraných a popsaných soft-computingových metod ve vývojovém prostředí LabVIEW nebo Matlab.
4. Ověření funkčnosti navrženého systému na syntetických i reálných signálech z klinické praxe.
5. Srovnání vlastností vybraných soft-computingových metod.
6. Diskuze dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] MARTINEK, Radek. *Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu*. Ostrava, 2014. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky. 150 s. Vedoucí diplomové práce doc. Ing. Jan Židek, CSc.
- [2] ROZTOČIL, Aleš a kolektiv. *Moderní porodnictví*. Praha: Grada Publishing, 2008, 408 s. ISBN 978-80-247-1941-2.
- [3] CHATURVEDI, Devendra K. *Soft computing: techniques and its applications in electrical engineering*. Springer Science & Business Media, 2008. ISBN 978-3-540-77481-5.
- [4] TUČKOVÁ, Jana. *Vybrané aplikace umělých neuronových sítí při zpracování signálů*. Praha: ČVUT, 2009. ISBN 978-80-01-04229-8.
- [5] ASSAIFI, Khalid. Extraction of fetal electrocardiogram using adaptive neuro-fuzzy inference systems. *IEEE Trans Biomed Eng.* 2007, 54(1), 59-68.
- [6] JANG, J.-S. Roger, Chuen-Tsai, SUN a Eiji MIZUTANI. *Neuro fuzzy and soft computing*:

a computational approach to learning and machine intelligence. Englewood Cliffs, NJ: Prentice-Hall, Inc., 1997. ISBN 0-13-261066-3/978-0132610667.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Radek Martiněk, Ph.D.**

Datum zadání: 01.09.2015

Datum odevzdání: 29.04.2016



doc. Ing. Jiří Kozíorek, Ph.D.
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

„Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární
prameny a publikace, ze kterých jsem čerpala.“

Dne: 28.4.2016

Podpis:



Poděkování

Ráda bych poděkovala svému vedoucímu diplomové práce panu doktorovi Radkovi Martinkovi za velmi kvalifikované odborné vedení, ochotu a pomoc při zpracování mé diplomové práce. Dále bych chtěla poděkovat své kolegyni Radaně Kahánkové za konzultace dosažených výsledků.

Abstrakt

Tato diplomová práce se zabývá návrhem softwarového řešení extrakce plodového elektrocardiogramu (fEKG) metodami soft computingu ze záznamů pořízených neinvazivním abdominálním monitorováním srdce plodu. Nejprve se práce věnuje rozsáhlé rešerši využití soft computingových metod v oblasti extrakce fEKG. Dále je v práci popsán návrh adaptivního softwarového řešení pro extrakci fEKG. Navržený systém se zakládá na adaptivním neuro-fuzzy interferenčním systému (ANFIS) s hybridním algoritmem učení. Funkčnost navrženého systému je otestována na syntetických i reálných datech. Hodnocení kvality filtrace je provedeno na základě SNR, RMSE a PRD. V práci se rovněž experimentálně prokazuje vliv nastavení parametrů adaptivního systému na kvalitu filtrace.

Klíčová slova

fEKG, mEKG, aEKG, soft computing, umělé neuronové sítě, ADALINE, evoluční algoritmy, genetické algoritmy, rojení částic (PSO), fuzzy systémy, hybridní algoritmy, ANFIS, SNR, RMSE, PRD

Abstract

This master's thesis deals with a proposal of software solution for adaptive fetal electrocardiogram (fECG) extraction by soft computing methods from non-invasive fetal heart monitoring. First part of this thesis is dedicated to a complex overview of soft computing methods used in fECG elicitation. Next part of thesis devotes to proposal of software solution for adaptive fECG extraction. The proposed adaptive system is based on adaptive neuro-fuzzy interference system (ANFIS) with hybrid learning algorithm. The functionality of the proposed system is tested by Signal to noise ratio (SNR), Root Mean Square Error (RMSE) and Percent Root Difference (PRD). Quality of fECG filtration is also evaluated for different setting parameters of the system.

Key words

fECG, mECG, aECG, Soft Computing, Artificial Neural Networks, ADALINE, Evolutionary Algorithms, Genetic Algorithms, Particle Swarm Optimizing (PSO), Fuzzy Systems, Hybrid Algorithms, ANFIS, SNR, RMSE, PRD

Obsah

Seznam použitých zkratk	9
Seznam obrázků	10
Seznam tabulek	11
Úvod	12
1. Řešení současného stavu problematiky extrakce plodového elektrokardiogramu metodami soft computingu	14
2. Softcomputingové metody	16
2.1. Umělé neuronové sítě	17
2.1.1. Formální model neuronu	17
2.1.2. Jednovrstvé neuronové sítě	18
2.1.3. Vícevrstvé neuronové sítě	20
2.2. Evoluční algoritmy	21
2.2.1. Genetické algoritmy	22
2.2.2. Evoluční strategie	26
2.2.3. Evoluční programování	27
2.2.4. Particle Swarm Optimization	27
2.3. Fuzzy systémy	29
2.4. Hybridní algoritmy	31
2.4.1. Adaptivní Neuro-Fuzzy Interferenční systém	31
2.4.1.1. Architektura ANFIS	31
2.4.1.2. Hybridní učící algoritmus pro ANFIS	32
2.4.1.3. Využití ANFIS pro extrakci fEKG	35
2.4.2. ANFIS realizace v Matlabu	35
2.4.2.1. Inicializace fuzzy systému	36
2.4.2.2. Popis příkazu anfis	37
2.4.2.3. Popis grafického prostředí ANFIS	38
3. Návrh a softwarová realizace systému pro extrakci fEKG	41
3.1. Návrh systému pro extrakci fEKG	41
3.2. Metody hodnocení kvality filtrace plodového elektrokardiogramu	42
3.2.1. Odstup signálu od šumu	42
3.2.2. Střední kvadratická chyba a relativní střední kvadratická chyba	43
3.2.3. Percentuální chyba	43
4. Ověření funkčnosti systému na syntetických i reálných datech	44

4.1.	Ověření funkčnosti systému na syntetických datech.....	44
4.1.1.	Jednoduchá syntetická data.....	44
4.1.1.1.	Popis jednoduchých syntetických dat	44
4.1.1.2.	Hodnocení kvality filtrace jednoduchých syntetických dat.....	45
4.1.2.	Syntetická data generovaná sofistikovaným generátorem.....	51
4.1.2.1.	Popis složitějších syntetických dat	51
4.1.2.2.	Hodnocení kvality filtrace složitějších syntetických dat	53
4.2.	Ověření funkčnosti systému na reálných datech z klinické praxe	59
4.2.1.	Popis reálných dat.....	59
4.2.2.	Hodnocení kvality filtrace reálných dat	60
5.	Srovnání vlastností vybraných soft computingových metod.....	63
5.1.	Vliv nastavení parametrů ANFIS na kvalitu filtrace.....	63
5.2.	Srovnání úspěšnosti filtrace u všech typů použitých dat	64
5.2.1.	Jednoduchá syntetická data.....	64
5.2.2.	Složitější syntetická data.....	64
5.2.3.	Reálná data	64
6.	Diskuze dosažených výsledků	65
	Závěr	66

Seznam použitých zkratek

aEKG	abdominální EKG
ADALINE	Adaptivní lineární neuron (Adaptive Linear Neuron)
ANFIS	Adaptivní Neuro-fuzzy Interferenční Systém
ANN	Umělé neuronové sítě (Artificial Neural Networks)
BPG	Algoritmus zpětného šíření chyby (Backpropagation algoritmus)
EA	evoluční algoritmy
EKG	elektrokardiogram
EP	evoluční programování
ES	evoluční strategie
fEKG	plodový (fetální) elektrokardiogram
FHR	fetální srdeční tepová frekvence (Fetal Heart Rate)
GA	genetické algoritmy
LMS	Metoda nejmenších čtverců (Least Mean Square)
MHR	tepová frekvence matky
mEKG	mateřský elektrokardiogram
MSE	střední kvadratická chyba (Mean Root Error)
PRD	percentuální odchylka (Percent Root Difference)
PSO	metoda optimalizace rojením částic (Particle Swarm Optimisation)
RTG	rentgen
RMSE	relativní střední kvadratická odchylka (Root Mean Square Error)
SC	soft computingové metody
SNR	odstup signálu od šumu (Signal to Noise Ratio)
SNRin	vstupní odstup signálu od šumu
SNRout	výstupní odstup signálu od šumu

Seznam obrázků

Obr. 1: Typy rušení fEKG.	14
Obr. 2: Schéma rozdělení softcomputingových metod.	16
Obr. 3: Formální neuron.	17
Obr. 4: Obecné schéma ADALINE.	19
Obr. 5: ADALINE aplikované na extrakci fEKG.	20
Obr. 6: Architektura dopředné ANN.	21
Obr. 7: Architektura rekurentní ANN.	21
Obr. 8: Základní schéma evolučního algoritmu.	22
Obr. 9: Schéma ruletové selekce na jednotkové kružnici.	23
Obr. 10: A) Jednobodové křížení, B) dvoubodové křížení.	24
Obr. 11: Schéma hybridního adaptačního FIR filtru v kombinaci s GA.	25
Obr. 12: Schéma hybridního adaptačního IIR filtru v kombinaci s GA.	26
Obr. 13: Schéma modelu Mamdani.	30
Obr. 14: Schéma modelu Sugeno.	30
Obr. 15: Architektura ANFIS.	31
Obr. 16: ANFIS editor v Matlabu.	38
Obr. 17: Příklad vykreslení signálu v ANFIS editoru.	39
Obr. 18: Blokové schéma navrhovaného systému.	41
Obr. 19: Vstupní jednoduché, syntetické signály systému.	45
Obr. 20: Srovnání výsledků SNRout v závislosti na počtu účelových funkcí pro různé epochy.	45
Obr. 21: Srovnání výsledků RMSE v závislosti na počtu účelových funkcí pro různé epochy.	47
Obr. 22: Srovnání výsledků PRD v závislosti na počtu účelových funkcí pro různé epochy.	48
Obr. 23: Srovnání výpočetní náročnosti v závislosti na počtu účelových funkcí pro různé epochy.	49
Obr. 24: Ukázka amplitud spekter fEKG a extrahovaného fEKG po filtraci.	50
Obr. 25: Výstup z ANFIS.	51
Obr. 26: Ukázka úvodní strany generátoru.	52
Obr. 27: Referenční a vstupní data systému generovaná sofistikovaným generátorem.	52
Obr. 28: Srovnání výsledků SNRout v závislosti na počtu účelových funkcí pro různé epochy.	53
Obr. 29: Srovnání výsledků RMSE v závislosti na počtu účelových funkcí pro různé epochy.	54
Obr. 30: Srovnání výsledků PRD v závislosti na počtu účelových funkcí pro různé epochy.	55
Obr. 31: Srovnání Výpočetní náročnosti v závislosti na počtu účelových funkcí pro různé epochy.	56
Obr. 32: Ukázka amplitud spekter srovnávající referenční fEKG s výstupním fEKG po filtraci.	58
Obr. 33: Srovnání vstupního aEKG a referenčního fEKG s výstupem z ANFIS.	59
Obr. 34: Prostředí EDF/EDF+ to WAV Convertor.	60
Obr. 35: Výsledky filtrace pro signál fECG_real17.	61
Obr. 36: Výsledky filtrace pro signál fECG_real29.	61
Obr. 37: Srovnání amplitud spekter vstupu a výstupu systému pro záznam fECG_real17.	62
Obr. 38: Srovnání amplitud spekter vstupu a výstupu pro záznam fECG_real29.	62

Seznam tabulek

Tabulka 1: Základní rozdělení ANN.	17
Tabulka 2: Využití ANN v medicíně	20
Tabulka 3: Popis dvou chodů hybridního algoritmu pro ANFIS	33
Tabulka 4: Specifikace počátečního nastavení funkcí příslušnosti pro <i>initFIS</i>	37
Tabulka 5: Způsoby nastavení <i>trnOpt</i>	37
Tabulka 6: Varianty nastavení <i>dispOpt</i>	38
Tabulka 7: Výsledky filtrace fEKG pomocí SNRout pro různý počet a typy účelových funkcí.	46
Tabulka 8: Výsledky filtrace fEKG pomocí RMSE pro různý počet a typy účelových funkcí.	47
Tabulka 9: Výsledky filtrace fEKG pomocí PRD pro různý počet a typy účelových funkcí.	48
Tabulka 10: Výpočetní náročnost filtrace pomocí ANFIS pro různý počet a typy účelových funkcí...49	
Tabulka 11: Výsledky filtrace fEKG pomocí SNRout pro různý počet a typy účelových funkcí.	54
Tabulka 12: Výsledky filtrace fEKG pomocí RMSE pro různý počet a typy účelových funkcí.	55
Tabulka 13: Výsledky filtrace fEKG pomocí PRD pro různý počet a typy účelových funkcí.	56
Tabulka 14: Výpočetní náročnost filtrace pomocí ANFIS pro různý počet a typy účelových funkcí...57	

Úvod

Plodový elektrokardiogram (fEKG) reflektuje elektrickou aktivitu srdce plodu. Asociace tepové frekvence s tísni plodu je známa již od 19. století. V druhé polovině 20. století se auskultační vyšetření tepové frekvence plodu (FHR) stalo běžnou klinickou praxí. V návaznosti na tuto metodu začaly vznikat první FHR monitory, jejichž rozmach přišel v polovině 70. let minulého století. Ačkoliv se od těchto monitorů očekávalo rapidní snížení úmrtnosti plodu v důsledku hypoxie, jejich technologie ještě nebyla dostatečně sofistikovaná, aby tato očekávání naplnila. Jejich výstupy byly často nespolehlivé a těžko interpretovatelné. Průlom ve FHR monitoringu způsobilo až použití modernějších metod zpracování signálu a lepší porozumění limitacím fEKG [58]. Současná diagnostika fEKG v gynekologii a porodnictví představuje zásadní metodu pro zjišťování hypoxických stavů plodu během těhotenství, ale také při samotném porodu. Monitorování FHR probíhá invazivními nebo neinvazivními metodami [38]. Jelikož se metody zpracování signálu dostaly na vysokou úroveň, je možné uvažovat nejen o diagnostice FHR, ale také o diagnostice celého fEKG, které obsahuje cenné informace o zdravotním stavu plodu. V současnosti se pro tuto diagnostiku využívají bezprostředně invazivní metody. Výzvu v této oblasti představuje zejména extrakce fEKG z neinvazivního abdominálního měření, které by eliminovalo průvodní komplikace související s invazivními způsoby měření. Problém neinvazivního způsobu měření spočívá v jeho zatížení nežádoucími šumy, v první řadě mEKG, které fEKG překrývá (např. [5], [6], [16], [38] a [51]). K odstranění tohoto nežádoucího šumu se v současné době testuje rozsáhlé spektrum adaptivních metod, které jsou předmětem této diplomové práce.


Předkládaná diplomová práce se zabývá extrakcí plodového elektrokardiogramu metodami soft computingu. Zaměření této práce je zacíleno na extrakci fEKG ze záznamů pořízených neinvazivními metodami monitorování. Snahou autora této práce je vytvořit softwarovou realizaci systému, který dokáže dvoukanálově (popř. multikanálově) extrahovat fEKG z abdominálního měření. Práce je rozdělena do dvou základní částí, do části teoretické a části praktické. Teoretická část práce se zabývá literární rešerší současného stavu řešené problematiky metodami soft computingu a popisem vybraných soft computingových metod s příkladem jejich aplikace na extrakci fEKG. V praktické části je popsán navržený adaptivní systém pro extrakci fEKG, pracující na základě zvolené soft computingové metody. Výběr vhodné soft computingové metody byl ovlivněn rešerší v teoretické části práce. Navržený systém je rovněž otestován na syntetických a reálných datech a dosažené výsledky účinnosti použité metody extrakce jsou zde rovněž srovnány a diskutovány.

TEORETICKÁ ČÁST

1. Rešerše současného stavu problematiky extrakce plodového elektrokardiogramu metodami soft computingu

Plodový elektrokardiogram (dále jen fEKG) je diagnosticky významným ukazatelem při monitorování stavu plodu (v současné době slouží především k prevenci hypoxie plodu ve snaze zabránit následkům hypoxie (hypoxicko-ischemická encefalopatie, smrt plodu), podrobněji např. v [40]. Jeho monitorování se provádí dvěma základními způsoby: invazivními a neinvazivními metodami. Invazivní metody obnáší transvaginální zavedení snímací elektrody přímo do lebky plodu. S invazivním monitorováním fEKG se ale váže jistá míra rizika v podobě natržení dělohy, krvácení a následného zánětu u matky nebo porušení nitrolebečních tlaků a zánětu u plodu. Vzhledem k těmto možným komplikacím budoucnost fEKG monitoringu směřuje spíše k neinvazivním metodám sběru dat, jejichž výsledky byly doposud považovány za méně relevantní. Proto se tato práce primárně zaměřuje na neinvazivní fEKG, které je získáváno pomocí břišních elektrod z abdominální oblasti (aEKG). Zaměření na neinvazivní metody měření fEKG podporuje také nejnovější rozsáhlá studie M. A. Belforta et al [57] z USA. Ta potvrzuje na základě 11 108 měření, že transvaginální monitorování plodu (tj. ST analýza) relevantně nezlepšuje výsledky při monitorování vzhledem k poměru kladů a záporů metody. V dalším textu budeme obecně značené fEKG považováno za neinvazivní fEKG, resp. aEKG. Jak již bylo uvedeno výše, fEKG je nositelem cenných diagnostických informací. V současné době se fEKG využívá především k prevenci hypoxie plodu na základě FHR, nicméně současné studie naznačují, že má daleko širší uplatnění: lze určit zralost, diagnostikovat srdeční vady plodu, dále pak detekovat vícečetné těhotenství, podrobněji v [5],[38] a [58]. Na základě těchto informací mohou lékaři včas předejít porodním komplikacím a nasadit vhodnou léčbu. Rozšíření uplatnění fEKG v diagnostice by mohlo vést k nahrazení stávajících přístrojů a metod mnohem levnějším řešením. Diagnostika na základě morfologie fEKG prozatím není proveditelná, jak je tomu například u invazivní metody STAN. Hlavní důvody jsou hned dva:

- I. Signál z aEKG nenese pouze signál fEKG, ale tvoří jej kombinace několika různých signálů zahrnující mateřské EKG (mEKG), svalovou aktivitu (EMG), 50 Hz rušení ze sítě, pohybové artefakty a další rušení. (viz Obr. 1) Tyto přebytkové signály je potřeba eliminovat. Obzvláště mEKG, které v aEKG dominuje a překrývá užitečný signál. Doposud ale nebyla vyvinuta spolehlivá metoda pro extrakci fEKG o dostatečné diagnostické kvalitě. Jednotlivé typy rušení blíže popisují například články [5],[31] a [38].



Obr. 1: Typy rušení fEKG [38].

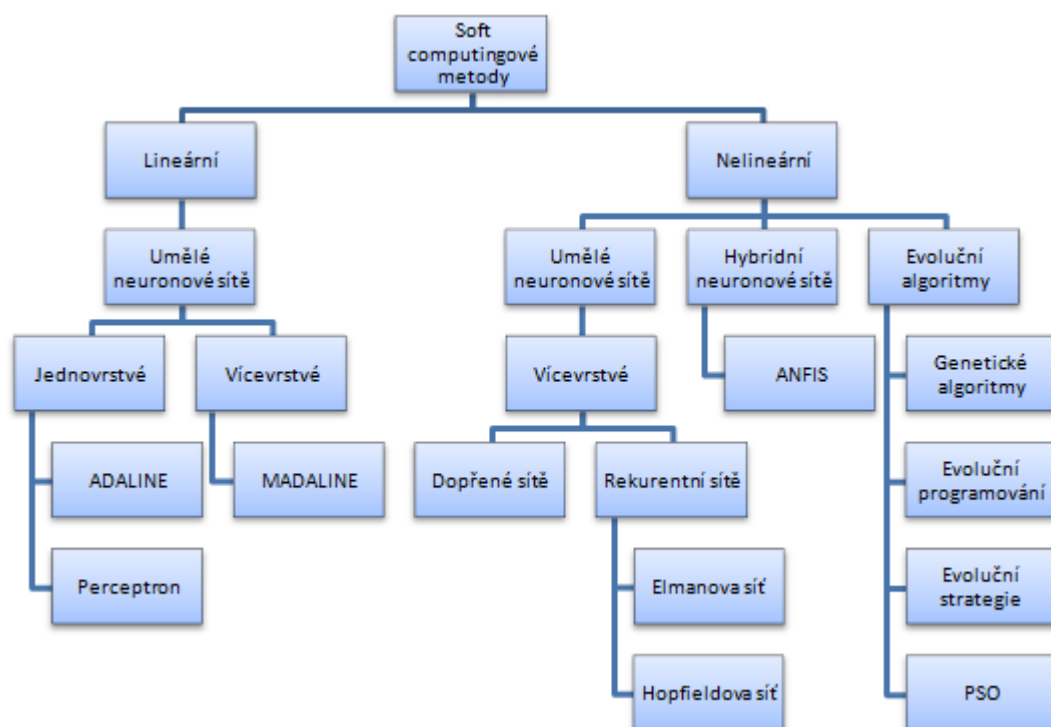
- II. Existuje pouze omezený počet databází, tzv. Gold Standard databases, které by shromažďovaly reálné, modelové, „normální“ a patologické fEKG signály. Příklad takovéto databáze naleznete např. na serveru <http://ecg.mit.edu/dbag/evnode3.htm> .

Diagnosticky kvalitní záznam fEKG musí obsahovat FHR (R-R interval), amplitudu různých vln a dobu trvání vln. Podle M. A. Hasan et al., [5], většina současných algoritmů pro zpracování aEKG detekují pouze R vlny fEKG signálu, zatímco vlny P, Q a další vlny zůstávají skryty. Extrakci diagnosticky kvalitního fEKG signálu navíc komplikuje fakt, že ji nelze snadno provést použitím klasických filtračních metod. Soft computingové (SC) metody extrakce fEKG by se tedy mohly stát klíčem k rozřešení problematiky extrakce fEKG z abdominálního měření. V průběhu posledních let se stále více studií zabývá aplikací SC metod na extrakci fEKG. Jak zmiňuje například článek Mamuna B. I. Reaze a Lee S. Weie, [1], nové výzkumy ukazují, že nelineární prostředí (jako je např. lidské tělo) se podstatně lépe modelují pomocí technologií umělé inteligence. SC metody zastoupeny fuzzy logikou, umělými neuronovými sítěmi (UNS), genetickými algoritmy a hybridními sítěmi se vyznačují tím, že dokážou oproti klasickým způsobům modelování pracovat s jistou mírou nepřesnosti. To dává těmto metodám před klasickým modelováním poměrně velkou výhodu, neboť u složitých reálných systémů jako je lidské tělo, je dosáhnout stoprocentní přesnosti prakticky nemožné. Další přednost SC metod spočívá v jejich schopnostech adaptovat se a učit se. Díky těmto schopnostem se velmi dobře uplatňují v adaptivních filtrech, kde jejich trénovací algoritmy umožňují přizpůsobovat a měnit parametry celého systému vzhledem k stávajícím okolnostem.

Příklad současně využívaných SC metod v oblasti extrakce fEKG představuje již zmíněný Reaz et al. 2004 [1], který použil adaptivní filtr vytvořený na základě adaptivního lineárního neuronu (ADALINE). Neuronové sítě jsou dále použity v [7]. V současnosti se největší oblibě těší hybridní metody kombinující neuronové sítě a fuzzy logiku, zejména metoda využívající Adaptivního Neuro-Fuzzy Interferenčního systému (ANFIS), které se věnují např. články [2], [4] a [6]. Genetické algoritmy jsou rovněž využívány v adaptivních modelech s cílem detekovat QRS komplex fetálního srdce [3]. Zajímavou roli v extrakci fEKG hrají také metody tzv. optimalizace hejnem částic (Particle Swarm Optimization – PSO) popsané například v [9] a [10].

2. Softcomputingové metody

Většina reálných fyzikálních a biologických systémů vytváří neuvěřitelně složité nelineární celky plné neurčitostí a nejasností, jejichž řešení je pro člověka bez použití technologií prakticky nemožné, jak z důvodu časové náročnosti řešení, tak množství zpracovávaných informací. Informace, které můžeme o těchto reálných systémech získat, mohou být dvojího charakteru: informace kvantitativní a kvalitativní. Kvantitativní informace reprezentují přesnou numerickou hodnotu, kterou získáme klasickým modelováním a matematikou a jsou součástí běžných rigidních výpočetních úkonů. Kvalitativní informace naopak obsahují znalost či zkušenost, kterou lze vyjádřit v přirozeném mluveném slově a zpracovávají se tzv. „soft“ (chápejme v překladu jako tvárný, poddajný) přístupem. Soft přístup pro zpracování informací je typický pro lidský mozek [8]. Jak bylo naznačeno v Kapitole 1, složité reálné problémy jsou velmi špatně popsitelné klasickou kvantitativní matematikou a aplikace metod zpracovávajících výhradně kvantitativní informace není efektivní a představuje značnou finanční zátěž. V moderních výpočetních technologiích se vědci snaží dosáhnout ideální kombinace kvalitativního a kvantitativního přístupu. Spojení obou přístupů a snaha přiblížit technologii lidskému myšlení vedly ke vzniku nových inteligentních soft computingových (SC) technologií. V současné praxi mají tyto metody velmi rozmanité pole využití. Rozdílné typy problémů vyžadují různé způsoby řešení, a proto každá SC metoda disponuje jinými vlastnostmi a postupy řešení [28] a [29]. Příkladem, fuzzy logika dovede skvěle pracovat s nepřesnostmi a neurčitostmi systému, neuronové sítě se věží k adaptaci a učení. V této kapitole budou podrobněji probrány jednotlivé SC metody, jejich matematické popisy a implementace v oblasti zpracování fEKG. SC metody, které s extrakcí fEKG přímo nesouvisí, budou zmíněny jen okrajově. Stručné rozdělení SC metod znázorňuje Obr. 2.



Obr. 2: Schéma rozdělení softcomputingových metod.

2.1. Umělé neuronové sítě


Umělé neuronové sítě (ANN) zahrnují SC metody kopírující chování biologické nervové soustavy živých organismů. Jsou to prakticky její zjednodušené matematické modely. Stejně jako u biologických neuronů v lidském těle také umělé neurony tvoří základní stavební jednotku systému. Na rozdíl od biologických neuronů jsou, ale tvořeny jednoduchými procesory. Tyto procesory mají schopnost přizpůsobovat své parametry (váhy, prahy), a tak mohou předpovídat následující chování procesu ze známých dat = učit se, adaptovat se a predikovat. Neuronové sítě vznikají spojením výstupů jednotlivých neuronů, které se propojují s dalšími neurony a vytvářejí tak kompaktní síť schopnou paralelního zpracování informací. Každý neuron v síti je schopen přijímat vstupní signál, zpracovat jej a vyslat výstupní signál. ANN nacházejí uplatnění všude tam, kde neznáme dopředu algoritmus řešení, kde je potřeba aproximovat funkční hodnoty a řídit nebo regulovat fyzikální veličiny. Velmi dobře si umějí poradit se zašuměnými signály. Dalšími typickými úlohami pro neuronové sítě mohou být např. rozpoznávání obrazců, detekce poruch či predikce signálu. Díky těmto schopnostem se používají mimo adaptivní filtraci fEKG také k rozpoznávání písma a rukopisu, k rozpoznávání řeči a dokonce k diagnostice fraktur z RTG snímků. Počet neuronů v síti a jejich vzájemné vazby určuje architektura neuronové sítě [18], [19], [20] a [21]. Architektura ANN se liší podle požadavků na vlastnosti systému. ANN lze rozdělit podle typologie, typu algoritmu učení a podle způsobu učení do tří kategorií, zaznačených v Tabulka 1.

Tabulka 1: Základní rozdělení ANN [45].

Podle topologie	Podle algoritmu učení	Podle způsobu učení
Jednovrstvé	S učitelem	Deterministické
Vícevrstvé	Bez učitele	Stochastické

2.1.1. Formální model neuronu

Nejběžnějším a nejstarším modelem umělého neuronu je tzv. formální neuron (označován podle zakladatelů také jako McCulloch-Pittsův neuron nebo binární prahový neuron [46]) viz Obr. 3, tvořený pevným počtem vstupů, neměnným prahem a jedním výstupem. Do neuronu vcházejí vzruchy ve formě binárních hodnot.



Obr. 3: Formální neuron [18].

Vstupy formálního neuronu (x_1 až x_n) jsou opatřeny vahami (w_1 až w_n), které představují uložení zkušeností do neuronu a určují důležitost a propustnost daného vstupu. Jeden vstup (θ) je připojen na nejvyšší úroveň signálu a zastává roli prahu. Hodnota tohoto prahu odpovídá váze fiktivního spojení mezi daným neuronem a neuronem fiktivním, jehož aktivita je rovna jedné. Aktivita

neuronu se odvíjí od porovnání vážené sumy všech vstupů vzhledem k hodnotě prahu. Neuron považujeme za aktivní, je-li vážená suma vstupů větší než hodnota prahu a naopak. Další důležitou součástí formálního neuronu představuje aktivační (též přenosová) funkce (S). Tato funkce zajišťuje transformaci vstupních parametrů na výstup neuronu (y) a udává způsob, jakým bude tato transformace provedena [18]. Matematické vyjádření formálního neuronu lze napsat takto [18]:

$$y = S\left(\sum_{j=1}^N w_j x_j + \theta\right). \quad (2.1.)$$

Kde:

y je výstup neuronu,

S je přenosová funkce,

$x_{1,2,...,j}$ jsou vstupy neuronu,

$w_{1,2,3...j}$ jsou váhy,

θ je speciální vstup, připojený na nejvyšší úroveň signálu (práh).

2.1.2. Jednovrstvé neuronové sítě

Jednovrstvé neuronové sítě se skládají pouze ze dvou vrstev neuronů, z vrstvy vstupní a vrstvy výstupní. Všechny výpočty jsou provedeny ve výstupní vrstvě. Nejzákladnější typy jednovrstvých sítí jsou popsány níže.

Perceptron

Nejjednodušší architekturu neuronové sítě představuje zobecnění formálního neuronu tzv. perceptron. Perceptron obsahuje jediný pracovní neuron McCullochova typu a vstupní signál je přenášén výhradně v binární nebo bifázické podobě. Aplikace perceptronu je limitována na řešení pouze problémů lineárního charakteru. Potenciál perceptronu je definován jako vážený součet všech vstupujících signálů. (viz rovnice 2.1) [18], [20], [21] a [22]. Aktivační funkce perceptronu v bifázické podobě má následující tvar [18]:

$$S(y_{in}) = \begin{cases} -1 & ; \text{pro } y_{in} < -\theta \\ 0 & ; \text{pro } -\theta < y_{in} < \theta. \\ 1 & ; \text{pro } y_{in} > \theta \end{cases} \quad (2.2.)$$

Aktivační funkce perceptronu v binární podobě [18]:

$$S(y_{in}) \begin{cases} 0 & ; \text{pro } x \leq 0 \\ 1 & ; \text{pro } x > 0 \end{cases} \quad (2.3.)$$

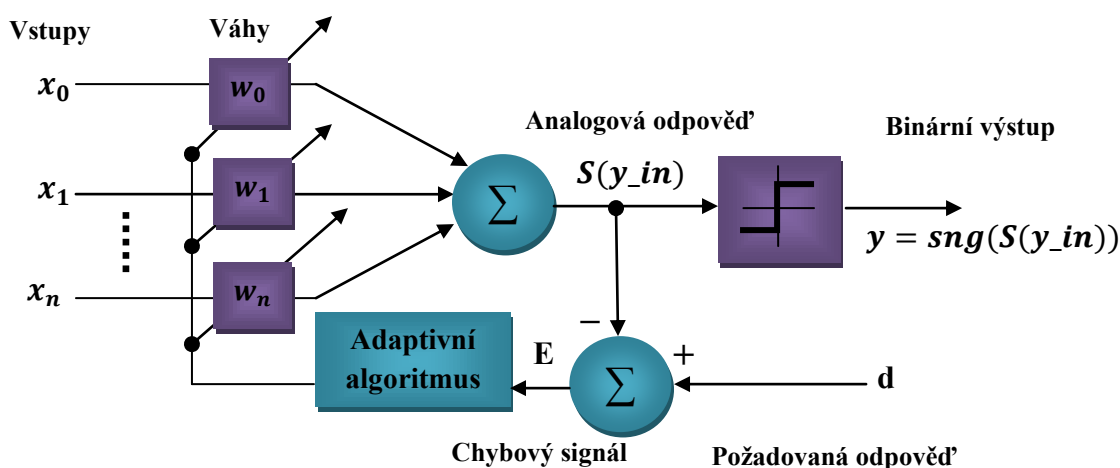
Adaptivní lineární neuron

V roce 1960 vynalezl Widrow adaptivní lineární neuron (ADALINE), který patří rovněž mezi jednoduché neuronové architektury s učitelem. Jedná se o jeden neuron McCulloch-Pittsova typu s lineární aktivační funkcí a zpětnovazebnou smyčkou. Je to adaptivní lineární prahový prvek. Stejně jako perceptron obsahuje více vstupů a jeden výstup, u ADALINE ovšem doplněných o doplňkový vstupní signál $x_0 = 1$ a speciální vstup d , obsahující požadovanou odpověď systému. Schéma ADALINE je znázorněno na Obr. 4. Na rozdíl od perceptronu mohou být u ADALINE vstupy w_1 až w_n analogové či binární, výstup je ale pouze binární. ADALINE provádí vážený součet vstupů vynásobených svými vahami. Tento vážený součet poté porovnává s hodnotou prahu.


[43] Překračuje-li hodnota váženého součtu vstupů hodnotu prahu, výstup neuronu je roven 1. Nepřekročí-li hodnotu prahu, výstup je roven 0:

$$S(y_{in}) = \begin{cases} 1 & \text{pro } \sum_{i=1}^n x_i w_i \geq \theta \\ 0 & \text{pro } \sum_{i=1}^n x_i w_i \leq \theta \end{cases} \quad (2.4.)$$

Trénování ADALINE je spjato s adaptací vah lineárního neuronu tak, aby se výstup co nejvíce přiblížil k požadované odpovědi d . Přizpůsobování vah docílíme adaptačními algoritmy, z nichž nejpoužívanější představuje algoritmus metody nejmenších čtverců (Least Mean Square-LMS). LMS u ADALINE minimalizuje součet čtverců lineárních odchylek v tréninkové sadě. Lineární odchylka E je v tomto případě definována jako rozdíl mezi požadovanou odpovědí d a hodnotou lineárního výstupu $S(y_{in})$. LMS algoritmus se označuje také jako tzv. delta učící pravidlo. ADALINE lze využít v adaptivních filtrech [1] a [15]. Příkladem aplikace ADALINE na extrakci fEKG je už několikrát zmiňovaná práce Mamuna B. I. Reaze a Leeho S. Weie [1], kteří použili ADALINE s adaptivním algoritmem ve formě LMS. Vstup sítě je v práci tvořen zašuměným mEKG, získaným z hrudní elektrody. Toto mEKG je třeba odfiltrovat. LMS algoritmus se snaží naučit, jak se mEKG změnilo průchodem skrz tělo pacientky směrem od hrudní k břišní elektrodě. Výstupem z ADALINE jen pak odhadovaný signál, ideálně roven mEKG měřenému na hrudní elektrodě. Jinými slovy LMS algoritmus se snaží vstupní signál mEKG co nejvíce přiblížit aEKG. Požadovaným signálem d je aEKG. Chybový signál E je poté roven rozdílu odhadovaného a požadovaného aEKG, který by měl být roven fEKG. Schéma ADALINE využitého pro extrakci fEKG znázorňuje Obr. 5.



Obr. 4: Obecné schéma ADALINE [12] a [22].



Obr. 5: ADALINE aplikované na extrakci fEKG [1].

2.1.3. Vícevrstvé neuronové sítě

V praxi jsou mnohem více zastoupeny rozsáhlejší ANN složené z většího počtu neuronů uspořádaných do vrstev, které označujeme jako vícevrstvé. Jednotlivé neurony v síti jsou spojeny alespoň s jedním dalším neuronem a každé spojení je ohodnoceno váhovým koeficientem, který reflektuje úroveň důležitosti spojení v neuronové síti [18]. Použití vícevrstevných ANN není limitováno podmínkou lineární separovatelnosti vstupních dat. Tyto ANN mohou být v medicíně využity hned několika způsoby, viz Tabulka 2:

Tabulka 2: Využití ANN v medicíně [44].


	Využití v medicíně	Příklad
1.	Modelování	modelování a simulace funkce mozku
2.	Zpracování signálu	odstranění šumů, neužitečných signálů
3.	Ovládání a kontrola systému	založených na odpovědi biologických nebo technických systémů
4.	Klasifikace do tříd	podobné informace (vzory, data) ukládá do tříd
5.	Predikce	z aktuálních dat dokáže odhadnout data následující

Vícevrstvé ANN se skládají nejméně ze tří základních vrstev – vstupní (distribuční) vrstvy, alespoň jedné skryté (vnitřní) vrstvy a výstupní vrstvy a podle topologie se rozdělují do dvou základních skupin, na sítě dopředné a rekurentní.

Dopředné (acyklické) neuronové sítě

Dopředné sítě jsou sítě s dopředným propojením a šířením signálu. To znamená, že neexistuje propojení mezi neurony v jedné vrstvě, ale pouze mezi vrstvami, kdy neurony v sousedních vrstvách jsou plně propojené (viz Obr. 6). Dopředné ANN patří mezi neuronové sítě, které pro učení potřebují znát cílové hodnoty = potřebují učící algoritmus. Nejčastěji používaný algoritmus učení (používaný asi v 80 % aplikací ANN) představuje tzv. algoritmus zpětného šíření chyby (back propagation-BPG). Tento algoritmus umožňuje minimalizovat chybovou funkci adaptací


synaptických vah. Zpětná distribuce chyby probíhá od výstupu a přes skryté vrstvy směrem k vstupu. Více informací o tomto algoritmu lze získat například z článků [18],[35],[36] a [37].



Obr. 6: Architektura dopředné ANN [18].

Rekurentní (cyklické) neuronové sítě

Rekurentní sítě jsou neuronové sítě, jejichž odezva není dána pouze aktuálním vstupním stimulem, ale odráží i vliv stimulů, které aktuální stimul přecházely, tzn., zahrnují do svých výpočtů také časový kontext. Obdobně jako u dopředných sítí, je zde pro adaptaci sítě využíván BCG algoritmus. Šíření signálu v rekurentních sítích neprobíhá pouze směrem od vstupu k výstupu, ale dochází ke zpětnovazebnímu šíření informace také z vyšších vrstev k vrstvám nižším (viz Obr. 7). Zpětná vazba je realizována prostřednictvím tzv. rekurentních neuronů, které jsou lokalizovány ve vstupní a vnitřní vrstvě sítě [43].




Obr. 7: Architektura rekurentní ANN [18].

2.2. Evoluční algoritmy

Stejně jako ANN si také evoluční algoritmy osvojují principy, které se běžně uplatňují v přírodě. Evoluční algoritmy (EA) jsou souhrnným názvem pro skupinu stochastických metod, které simulují přirozené biologické evoluční procesy probíhající podle Darwinovy teorie vývoje populace a

aplikují je do oblastí vyhledávání, optimalizace a řízení. Zjednodušeně Darwinova teorie říká, že každá populace stejného druhu obsahuje jedince s různými genetickými odchylkami. Vzhledem k velkému množství potomků v populaci, dochází k boji o přežití, kde vítězí nejsilnější jedinci s nejvýhodnějšími genetickými odchylkami. Nejsilnější jedinci poté zakládají novou generaci a přenášejí na ni své výhodné geny. EA představují jednoduché modely této teorie přenesené do oblasti výpočetní techniky. Základní schéma EA znázorňuje Obr. 8. Všechny EA pracují heuristicky, tzn., operují s celou populací potencionálních řešení (jedinců) na základě náhodných změn těchto řešení. Kvalita jednotlivých řešení je dána tzv. hodnotou fitness. Pokud jsou nová řešení lepší než řešení stávající, podle evoluční teorie původní řešení jednoduše nahradí. Zároveň by měly EA zajišťovat splnění dvou základních cílů: co nejrychleji najít nejbližší optimum a přitom co nejlépe prohledat prostor všech možných řešení. Jelikož EA pracují současně s celou populací řešení, umožňují paralelní zpracování. Přednost EA před matematickými metodami spočívá v obecnosti těchto metod, která je činí aplikovatelné na téměř jakýkoliv problém. Velkým přínosem je také jejich schopnost neustrnout v lokálním extrému. Na druhou stranu oproti klasickým matematickým metodám jsou výpočty značně pomalejší a metody nejsou účinné, není-li znám globální extrém. Také výběr vhodného algoritmu a volba vhodných parametrů pro nastavení není jednoznačná, v současnosti se postupuje metodou pokusu a omylu. EA rovněž modelují přírodní evoluční procesy, jako jsou selekce, křížení, mutace, rekombinace, migrace, lokalizace a sousedství. Do skupiny EA se řadí například genetické algoritmy (GA), evoluční strategie (ES), evoluční programování (EP) a rojení částic (PSO) [54],[55].



Obr. 8: Základní schéma evolučního algoritmu [34].

2.2.1. Genetické algoritmy

Genetické algoritmy (GA) se inspiřují v základech biologické genetiky a mechanismech přirozeného výběru, odkud převzaly i část své terminologie. Parametry jednotlivých jedinců v populaci jsou zde nazývány geny a pracují s binárním kódováním. Geny se dále pojí v řetězce, označované jako chromozomy a sada parametrů v chromozomu se nazývá genom. Důležitou roli v GA hraje fitness hodnota vyjadřující kvalitu každého jedince, tzn. procentuální podíl výhodnosti použití daného jedince jako rodiče (jinak označována jako vhodnost). Fitness hodnota je transformovaná hodnota účelové funkce¹ na hledání maxima a obvykle představuje reálné číslo v jakémkoliv libovolném intervalu. Z praktických důvodů se nejčastěji transformuje na normovaný interval [0,1]. Transformační funkce se nazývá tzv. fitness funkcí, která je popsána vztahem 2.5 :

¹ **Účelová funkce** = matematický model řešeného problému, kdy řešení dosáhneme maximalizací nebo minimalizací funkce.

$$F(i) = \frac{F_{max} - F_{min}}{f_{min} - f_{max}} f(i) + \frac{f_{min} F_{min} - f_{max} F_{max}}{f_{min} - f_{max}}. \quad (2.5.)$$

Kde:

$F(i)$ je fitness hodnota jedince,

$f(i)$ je hodnota účelové funkce aktivního jedince,

F_{max} je maximální fitness hodnota,

F_{min} je minimální fitness hodnota,

f_{max} je maximální hodnota účelové funkce,

f_{min} je minimální hodnota účelové funkce.

Činnost GA zajišťují tři základní operace, které se v dané generaci aplikují vždy na celou populaci, čímž vzniká nová generace:

I. Výběr rodičů (Selekce).

II. Křížení.

III. Mutace.

Operátor selekce zajišťuje výběr jedinců z populace, kteří jsou podle nastavených parametrů vhodnými kandidáty stát se rodiči. Výběr rodičů představuje klíčový okamžik pro správný běh GA. Podle evoluční teorie jsou vhodní rodiče ti lepší jedinci z populace, musí se ale počítat i s faktem, že i horší jedinci mohou přinést vhodné geny pro další vývoj. Výběr kandidátů probíhá různými metodami, nejčastěji se však pracuje s fitness hodnotou. Existuje hned několik typů selekce, v literatuře se uvádí: náhodná selekce, selekce elity, turnajová selekce a selekce na principu rulety. Selektce na principu rulety je nezmínovanějším a zároveň jedním z nejstarších typů selekce (např. v [20], [54], a [55]). U tohoto typu selekce je každému jedinci z populace přiřazen procentuální podíl výše ze pomyslné rulety na základě jeho fitness hodnoty. Z takto rozděleného kola rulety se losují rodiče pro další generaci. Celé kolo rulety má rozsah $\langle 0; 1 \rangle$. Pravděpodobnost p_i , s jakou bude jedinec vybrán lze matematicky vyjádřit takto pomocí vzorce 2.6 (dle [54]):


$$p_i = \frac{F(i)}{\sum_{i=1}^N F(i)}. \quad (2.6.)$$

Kde:

p_i je pravděpodobnost, s jakou bude i -tý jedinec vybrán,

$F(i)$ je fitness hodnota jedince,

N je počet jedinců v populaci,



Obr. 9: Schéma ruletové selekce na jednotkové kružnici [54].

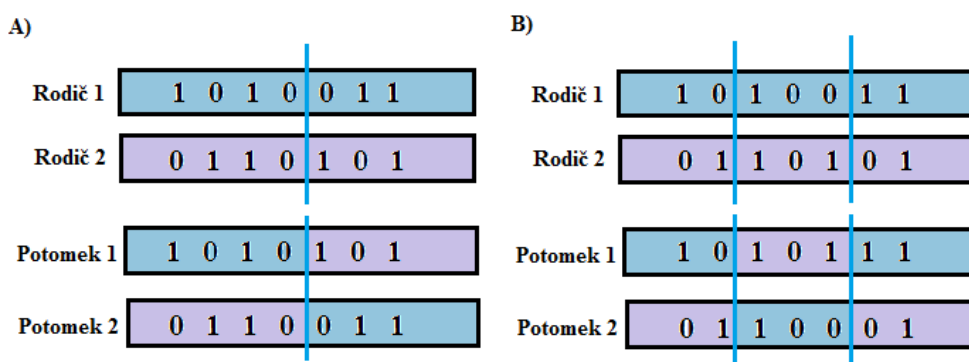
Schéma na Obr. 9 se dá interpretovat také pro populaci s nepřerodělenými hodnotami účelové funkce. Pro obě varianty existuje algoritmus:

I. Suma všech účelových hodnot v populaci S

- II. Vygenerování náhodného čísla r z intervalu $[0, S]$
- III. Průchod populací a počítání sumy účelových hodnot od hodnoty nula s

Jestliže se hodnota s stane větší než hodnota r , vybere se jedinec do reprodukčního pole. Aby bylo dosaženo lepšího průběhu GA, začal se zavádět také tzv. elitismus. To znamená, že se nejprve vybere nejlepší jedinec z populace a zařadí se do populace nové. Teprve poté se začne se selekcí.

Na selekci navazuje operace křížení. Křížením dochází k vzájemné výměně části chromozomů mezi rodiči, kdy ze dvou rodičů vznikají dva potomci nové generace. Nejjednoduššími kříženími jsou křížení jednobodové a dvoubodové. U jednobodového křížení se v chromozomech obou rodičů určí jeden bod, ve kterém se chromozomy rozdělí na dvě části a rodiče si je mezi sebou vymění. U dvoubodového jsou tyto body dva. Obě tyto metody jsou porovnány na Obr. 10. Křížení může vznikat také vícebodově (příliš se nepoužívá) nebo kombinací více než dvou rodičů. Rovněž se může stát, že se do nové generace dostanou také někteří rodiče.



Obr. 10: A) Jednobodové křížení, B) dvoubodové křížení [54].

Třetí a poslední operace je mutace. Jedná se o náhodné změny o nízké pravděpodobnosti v chromozomech jedinců nové generace za účelem objevení vlastnosti, kterou doposud žádný jedinec nedisponoval a nemohl ji předat. Nejčastěji se mutace projevuje změnou jednoho genu v chromozomu, např. 0 na 1.

Princip funkce GA můžeme shrnout následovně. Algoritmus inicializuje práci s nějakou náhodně zvolenou populací, kterou následně zdokonaluje a to tak dlouho, dokud nedosáhne splnění nějaké podmínky nebo nedosáhne maximálního času (počtu generací). Nejčastější podmínkou pro ukončení algoritmu bývá dosažení předem stanoveného maxima pro fitness funkci. Detailněji vlastní činnost GA probíhá následovně:


- I. Inicializace = určí se velikost populace a náhodně se vygenerují chromozomy všech jedinců, kterým se stanoví fitness hodnota. Zároveň se určí hodnota globálního maxima a maximální počet možných nových generací.
- II. Selektce.
- III. Křížení.
- IV. Mutace.
- V. Vyhodnocení = u nově vzniklé generace se hodnotí, zda obsahuje jedince, který splňuje požadovanou podmínku. Pokud se takový jedinec v populaci najde, algoritmus končí.
- VI. Nahrazení = nově vygenerovaná generace nahradí stávající generaci.
- VII. Cyklické opakování = od bodu č. II. dokud nenalezne žádané optimum nebo neuplyne maximální čas.

2.2.1.1. Využití GA pro extrakci fEKG

Pro extrakci fEKG se nejčastěji používají GA v kombinaci s neadaptivními metodami filtrace pomocí FIR/IIR filtrů, jak dokazují např. články [23][25]. M. Talha et al [23] použil pro extrakci fEKG FIR optimalizovaný GA. Použitý FIR filtr typu pásmová propust o frekvenci $f = 0,01\text{Hz} - 100\text{Hz}$ měl charakteristiku: vzorkovací frekvence $f_{vz} = 300\text{Hz}$, mezní frekvenci $f_{cut-off} = 75\text{Hz}$, počet koeficientů $N = 31$. Aby byl výsledek filtrace fEKG co možná nejlepší, musí být vhodně nastaveny koeficienty FIR filtru. GA tyto koeficienty modifikují a snaží se nalézt jejich optimální hodnotu. V článku je popsán následující postup optimalizace. Nejprve se GA iniciovalo. Toho se docílilo výběrem náhodné populace z rozsahu frekvencí FIR. Frekvence vybrané do populace se zakódovaly do binární podoby N bity, pomocí vztahu (2.7.):


$$f_{cod} = (2^N - 1) \frac{f - f_{min}}{f_{max} - f_{min}}. \quad (2.7.)$$

Následně proběhla evaluace, kdy se pro každé vlnové pásmo spočítal vektor koeficientů optimálního filtru. Frekvence byly klasifikovány do tříd a zhodnotila se jejich pravděpodobnost reprodukce. Pro reprodukci byly vybrány nejvhodnější frekvence podle jejich fitness funkce. Fitness funkce byla spočítána pomocí algoritmu LMS.



Obr. 11: Schéma hybridního adaptačního FIR filtru v kombinaci s GA [23].

Kam a Cohen [25] místo FIR filtru použili IIR filtr v kombinaci s GA. Článek potvrzuje, že extrakční systém pro fEKG tvořený kombinací IIR filtru a GA dosahuje lepších výsledků v extrakci fEKG, než systém tvořený pomocí kombinace FIR filtru a GA.



Obr. 12: Schéma hybridního adaptačního IIR filtru v kombinaci s GA [25].

2.2.2. Evoluční strategie

Evoluční strategie (ES) také patří mezi nejstarší evoluční algoritmy. V 60. letech minulého století ji vynalezli Schwefel a Rachenberg. ES se od GA liší v několika bodech. Zaprvé, jedinci v ES jsou reprezentováni jako vektory reálných čísel. Navíc u původní ES se pro výpočty využívaly pouze operátory selekce a mutace, křížení bylo z celého procesu vynecháno. Novější verze ES byly později dodatečně doplněny i o operátor křížení. První verzi ES představuje dvoučlenná ES označovaná také $(1 + 1) - ES$. Jedná se o strategii, kdy z rodičovské generace o velikosti 1, vzniká generace potomků rovněž o generaci velikosti 1. Jinými slovy lze říci, že nový jedinec vzniká mutací z jednoho rodiče. Následně na základě selekce v podobě turnajového výběru je vybrán silnější jedinec, který přežije. Popsáno matematicky, nový jedinec y se generuje jako mutace jedince x tak, že se složky vektoru x změní přidělením normálně rozdělených hodnot náhodných veličin u . Významný vliv na výkon ES má mutace, konkrétně její směrodatná odchylka Gaussova rozdělení (σ). Tu lze podle určitých pravidel určit.

$$y = x + u \quad \text{kde} \quad u \sim N(0, \sigma^2 I). \quad (2.7.)$$

Aby byla mutace úspěšná, musí splňovat následující podmínku: nově vzniklý potomek musí být silnější než rodič. Podle pravidla $\frac{1}{5}$ by mělo platit, že poměr úspěšných mutací p_s ke všem mutacím je $\frac{1}{5}$. S faktorem intenzity mutace c_d vypadá pravidlo následovně.

$$\sigma^{t+1} = \begin{cases} c_d \sigma^t & \text{jestli } p_s < \frac{1}{5} \\ \frac{\sigma^t}{c_d} & \text{jestli } p_s > \frac{1}{5}; c_d = 0,817. \\ \sigma^t & \text{jestli } p_s = \frac{1}{5} \end{cases} \quad (2.8.)$$

Jako novější variantu ES představil Rechenberg vícečlenné ES nebo také $(\mu + 1) - ES$, $\mu > 1$. Mezi další verze ES patří např. rekombinační a adaptivní ES, jejichž detailnější popis naleznete např. [55].

2.2.3. Evoluční programování

Evoluční programování (EP), je další z evolučních algoritmů, které vznikaly v 60. letech minulého století. Základ EP tvoří prohledávání prostoru možného řešení. Výběr dat probíhá náhodným zařazením dat do skupin, které mohou obsahovat, jak nové jedince, tak jejich rodiče. Metodou turnajové selekce jsou pak tito jedinci seřazeni podle síly a nejlepší jedinci jsou vybráni do další populace. Vzhledem k předchozím evolučním algoritmům EP úplně vynechává operaci křížení, což této metodě poskytuje výhodu v oblasti překonávání falešného lokálního minima. Mutace pak probíhá obdobně jako u předchozích typů evolučních algoritmů.

2.2.4. Particle Swarm Optimization

Optimalizace hejnem částic z ang. Particle Swarm Optimization (PSO) je robustní stochastická optimalizační metoda kopírující sociální inteligenci některých živočišných druhů žijících v hejnech, jako jsou například ptáci či některé druhy ryb. Konkrétně aplikuje koncept sociálního chování a interakce místo čistě individuálních kognitivních vlastností jedince hejna na řešení výpočetních problémů. Tuto metodu poprvé představili světu v roce 1995 Kennedy a Eberhart a od té doby prošla četnými modifikacemi v návaznosti na práci dalších vědeckých týmů s cílem vylepšení metody [54]. Obdobně jako GA je inicializována populací náhodných řešení a hledá optimální řešení hledáním nových, lepších generací. Na rozdíl od GA, ale nepoužívá žádné evoluční operátory (selekce, křížení, mutace). Trajektorie částice je dána trajektorií částic, které mají nejlepší vhodnost.

2.2.4.1. Princip PSO

Kennedyho originální PSO pracuje s hejnem (populací) náhodně vybraných částic, které se pohybují v n -dimenzionálním reálném prostoru možného řešení problému. Částice v hejnu jsou opatřeny třemi n -dimenzionálními vektory – vektorem aktuální polohy \vec{x} , vektorem předchozí nejlepší polohy \vec{p} a vektorem rychlosti \vec{v} , a dále svou vlastní vnitřní pamětí, do které ukládají svou aktuální a nejlepší nalezenou polohu. Aktuální poloha částice představuje souřadnice jednoho bodu v prostoru. Každá částice má za úkol, vyhodnocovat fitness funkci v poloze, kde je umístěna. Pokud je aktuální poloha částice \vec{x} vyhodnocena jako lepší, než jakákoliv její poslední uložená nejlepší hodnota \vec{p} , aktuální poloha \vec{x} se ukládá jako nová nejlepší poloha \vec{p} do proměnné $pbest$. Pohyb částic v prostoru je podmíněn jejich vlastní aktuální a nejlepší polohou a také nejlepší polohou sousedních částic. Z pozice všech částic je vypočtena hodnota účelové funkce. Částice s nejnižší a nejvyšší hodnotou uloží svou hodnotu do společné paměti populace. Nové vyhodnocování je zahájeno až ve chvíli, kdy se přesunou všechny částice v hejnu na novou pozici. U správně provedené PSO by se mělo hejno při každém opakování posouvat stále blíže k požadovanému optimu, dokud jej nedosáhne. Algoritmus Kennedyho PSO je popsán takto:

- I. Inicializace = určí se velikost populace částic, kterým se náhodně přisoudí aktuální poloha a rychlost v prohledávaném prostoru.
- II. Smyčka.
- III. Vyhodnocení = vyhodnotí se požadovaná optimalizace fitness funkce pro každou částici
- IV. Srovnání = porovnají se fitness hodnoty všech částic s proměnnou $pbest$. Pokud je aktuální poloha částice lepší, než stávající hodnota $pbest$, nahradí ji.
- V. Identifikace nejlepší sousední částice = částice identifikuje jednu částici nejlepší částici ve svém sousedství a uloží si její souřadnice do proměnné g
- VI. Změna polohy a rychlosti částice = podle následující rovnice:

$$\begin{cases} \vec{v}_i \leftarrow \vec{v}_i + \vec{U}(0, \phi_1) \otimes (\vec{p}_i - \vec{x}_i) + \vec{U}(0, \phi_1) \\ \vec{x}_i \leftarrow \vec{x}_i + \vec{v}_i \end{cases} \quad (2.9.)$$

Kde:

$\vec{U}(0, \phi_1)$ je vektor reprezentující náhodná čísla rozmístěná v intervalu $[0; \phi_1]$ pro každou částici při každém opakování algoritmu,

\otimes je component-wise multiplication.

- VII. Cyklické opakování = od bodu č. II se algoritmus opakuje tak dlouho, dokud nedosáhne požadovaného kritéria nebo maximálního nastaveného počtu opakování.
- VIII. Ukončení smyčky = algoritmus dosáhl kritéria, nebo maximálního počtu opakování.

Pro správnou funkci algoritmu je nutné vhodně volit parametry populace částic. Mezi tyto parametry patří (převzato z [54]):

- Dimenze – Jedná se o počet argumentů účelové funkce. Každý jedinec má ve vektoru pozice i rychlosti právě tolik argumentů jako je číslo dimenze řešeného problému.
- Rozsah – Spolu s dimenzí udává velikost prohledávaného prostoru. Pomocí vzorového jedince (specimen) se určuje pro každou dimenzi oblast možného řešení. Tato oblast musí být dána alespoň dvěma intervaly.
- Počet částic – Definuje počet jedinců, kteří budou hledat optimální řešení. S rostoucím počtem částic bude prostor prohledán hustěji, ale doba hledání řešení se zvýší. Platí, že počet částic by se měl rovnat $10 \times \text{Dimenze}$, obvykle tedy v rozmezí 20 – 40 částic.
- v_{max} – Určuje maximální rychlost částice. Malá rychlost vzhledem k velikosti prohledávaného prostoru způsobí, že částice prohledávají prostor blízko své počáteční pozice. To vede sice k důkladnému prohledání ale pouze velmi malé oblasti. Příliš velká rychlost naopak může vést k překročení povolených mezí prohledávané oblasti. Obvykle se v_{max} nastavuje na hodnotu rozsahu, podle testů z [54] je ale vhodnější použít v_{max} o velikosti $\frac{1}{20}$ rozsahu.
- Učící faktory c_1, c_2 – Ovlivňují tendence posuvu částic. Částice hejna reagují na tři základní podněty: původní směr pohybu, postup ke svému nejlepšímu výsledku () a postup k doposud nejlepšímu řešení v populaci částic. Učící faktor c_1 dává v rozhodování o směru pohybu přednost návratu na svou dosud nejlepší pozici před následováním nejlepšího výsledku v populaci. Učící faktor c_2 naopak upřednostní tendenci posuvu částice k nejlepšímu výsledku v populaci.
- Setrvačnost (váha) – Malá hodnota setrvačnosti podporuje hledání lokálních extrémů, velká hodnota hledání globálních extrémů.

2.2.4.2. Využití PSO při extrakci fEKG

K PSO se při extrakci fEKG přistupuje jako k učicímu algoritmu pro hybridní síť ANFIS (podrobněji popsána v kapitole 2.4.1). Četné výzkumy se zabývají implementací PSO do architektury ANFIS a srovnáním PSO jako učicího algoritmu s jinými učicími algoritmy, používanými pro extrakci fEKG metodou ANFIS, např.[6], [51], [52] a [53]. Velkou výhodou kombinace ANFIS metody s metodou PSO je zejména schopnost extrahovat nejen QRS komplex, ale všechny komponenty fEKG, tedy celý PQRSTU komplex. Toho prozatím nebylo dosaženo žádnou jinou dvoukanálovou metodou. Další výhodou, společnou se všemi EA, představuje schopnost PSO neustrnout v lokálním minimu.

2.3. Fuzzy systémy

Fuzzy logika, která sdružuje metody zabývající se aproximací řešení s tolerancí nepřesností (neprecizností) výsledného řešení, tvoří základ všech fuzzy systémů. Výraz fuzzy lze v překladu chápat jako neurčitý, či nejasný. Poprvé byla fuzzy logika vynalezena v roce 1965 profesorem L. A. Zadehem, který o této problematice následně napsal celou řadu vědeckých článků a publikací, příkladem [26], [27], [28] a [29]. Účelem systémů založených na fuzzy logice je promítnout způsob, jakým člověk (expert) dochází na základě zkušenosti k řešení problému do různých vědních či ekonomických oblastí, např. na problematiku zpracování signálu a do řídicích systémů. Lidské zkušenosti jsou ve fuzzy logice formulovány jako výrazy či celé věty přirozeného jazyka. Prostřednictvím fuzzy logiky lze nenumernickou matematikou vyjádřit také výrazy jako „malý“, „tak akorát“ či „velký“. Jak je z uvedených příkladů patrné, právě výrazy přirozeného jazyka jsou nositeli neurčitosti (vágnosti). Neurčitost se ve složitých systémech formalizuje pomocí fuzzy množin. Míra příslušnosti $\mu(x)$ jednotlivých prvků do množiny není na rozdíl od klasické logiky dána pouze dvouhodnotově- tzn. prvek do množiny absolutně patří ($\mu(x) = 1$) nebo absolutně nepatří ($\mu(x) = 0$), ale pohybuje se v intervalu $[0,1]$. Jak již bylo naznačeno, jazykový popis systému zprostředkovává nenumernická matematika. Jejím základním stavebním kamenem je jazyková proměnná. Podle L. A. Zadeha [30] je jazykovou proměnnou právě taková proměnná, která obsahuje prvky, jejichž hodnoty jsou lingvistické. Jako jazykovou proměnnou si můžeme představit například „velikost“. Jazykovými hodnotami této jazykové proměnné uvažujeme „obrovský“, „hodně velký“, „velký“, „malý“, „hodně malý“ atd. L.A.Zadeh dále uvádí, že jazyková proměnná se skládá z pěti částí.

- Identifikátoru jazykové proměnné \mathcal{X} .
- Množina jazykových hodnot, kterých může jazyková proměnná nabývat $T(\mathcal{X})$
- Univerzum diskurzu U
- Syntaktické pravidlo G = pravidlo, jehož prostřednictvím se generují prvky množiny $T(\mathcal{X})$.
- Sémantické pravidlo M = přiřazuje každé jazykové hodnotě význam.

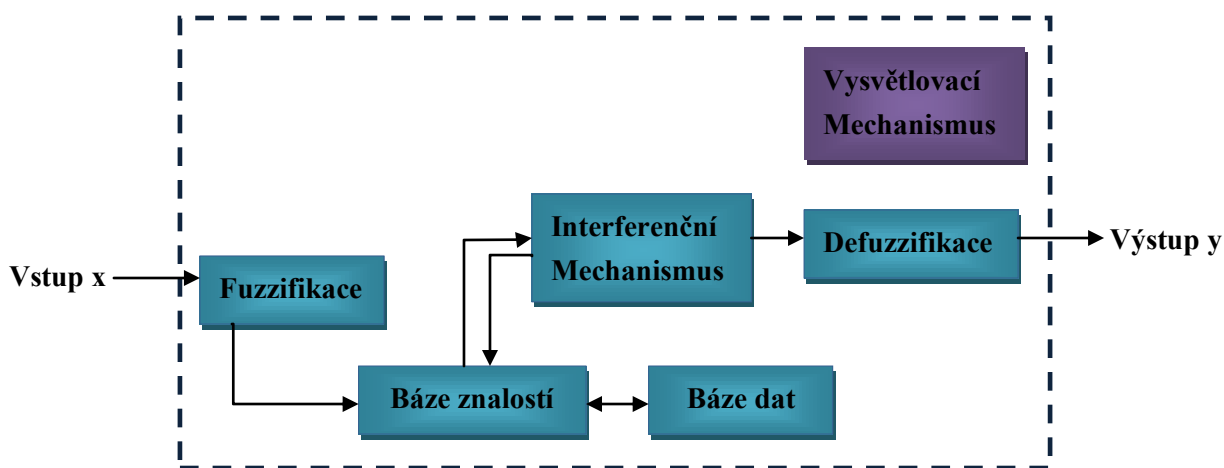
Fuzzy interferenční systémy (FIS) lze označit za univerzální aproximátory libovolné spojité funkce. Kromě jejich výhody v oblasti zpracování neurčitých dat, oplývají fuzzy dalšími významnými přednostmi. Zejména jsou mnohem srozumitelnější, především v interpretaci znalostí než jiné typy systémů, jejich návrh je jednodušší a při změnách parametrů či změně počtu modulů není potřeba celý systém přepracovávat [42]. FIS se dělí na dva základní typy: typ Mamdani a typ Takagi Sugeno. U obou těchto systémů tvoří vstupy fuzzy množiny. Výstupem Mamdani systému je rovněž fuzzy množina (nebo množiny), použitím Sugeno systému, ale na výstupu získáme předpis tvořený lineární kombinací vstupů. Schéma modelu Mamdani znázorňuje

Obr. 13, průběh Mamdani algoritmu je popsán níže:

- I. Vstup.
- II. Fuzzifikace = každému vstupnímu prvku je přiřazena $\mu(x)$ k fuzzy množině
- III. Báze znalostí = zde se ukládají pravidla vytvořená na základě báze dat, kterými se fuzzy systém řídí. Jedná se o tzv. IF-THEN podmínky. Obecně, máme-li vstupní jazykové proměnné x a y s jazykovými hodnotami A_i a B_i , a výstupní jazykovou proměnnou z s jazykovými hodnotami C_i pak IF-THEN podmínka může mít příkladem následující tvar:

$$\text{IF } (x \text{ is } A_i) \text{ AND } (y \text{ is } B_i) \text{ THEN } (z \text{ is } C_i) . \quad (2.10.)$$

- IV. Báze dat = jsou zde uloženy parametry jednotlivých jazykových proměnných.
- V. Interferenční mechanismus = na základě báze znalostí počítá výsledek.
- VI. Vysvětlovací mechanismus = pomocný aparát, který zobrazuje, jaká pravidla byla při zpracování aktivní.
- VII. Defuzzifikace = z výsledné fuzzy množiny se vypočítá numerická hodnota výstupu jako poloha těžiště plochy S této fuzzy množiny.
- VIII. Výstup.



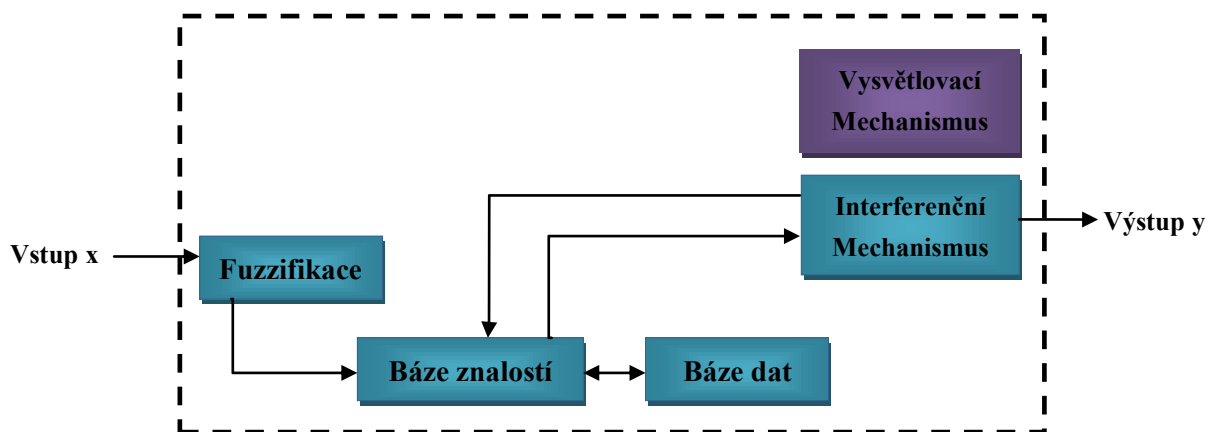
Obr. 13: Schéma modelu Mamdani.

Algoritmus FIS typu Sugeno (viz Obr. 14):

- I. Vstup.
- II. Fuzzifikace.
- III. Báze znalostí= IF-THEN podmínka Sugeno modelu má trochu odlišný tvar, než podmínka modelu typu Mamdani. Má-li podmínka jazykovou proměnnou x a y a jazykové hodnoty A_i a B_i , pak je konsekvent funkcí f_i vstupních proměnných ve tvaru:

$$\text{IF}(x \text{ is } A_i) \text{ AND } (y \text{ is } B_i) \text{ THEN } (f_i = p_i x + q_i y + r_i). \quad (2.11.)$$

- IV. Báze dat.
- V. Interferenční mechanismus.
- VI. Vysvětlovací mechanismus.
- VII. Výstup.



Obr. 14: Schéma modelu Sugeno.

2.4. Hybridní algoritmy

2.4.1. Adaptivní Neuro-Fuzzy Interferenční systém


V roce 1993 J. S. R. Jang vynalezl adaptivní neuro-fuzzy interferenční systém (ANFIS), který v současné době patří k nejčastěji využívaným hybridním adaptivním systémům v oblasti extrakce fEKG. Jedná se o adaptivní síť tvořenou FIS typu Sugeno doplněnou o strukturu dopředných neuronových sítí a učící algoritmus neuronových sítí. Přednost tohoto hybridního systému představuje zejména schopnost kombinovat dovednosti neuronových sítí a fuzzy systémů v učení nelinearit, které se navzájem doplňují. Neuronové sítě propůjčují fuzzy systému své schopnosti učení se z okolí. Fuzzy logický systém pak poskytuje neuronové síti strukturu a umožňuje zpracování i nepřesných dat [11], [17]. ANFIS používá dva typy učících algoritmů: BPG algoritmus nebo hybridní algoritmus tvořený kombinací BPG a LMS algoritmu [2]. Hybridní algoritmus bude jako stěžejní algoritmus praktické části práce podrobněji popsán v podkapitole 2.4.1.2.

Správně funkční ANFIS musí disponovat několika základními vlastnostmi:

- Systém má jeden výstup.
- Obsahuje Sugeno model nultého nebo prvního řádu.
- Počet pravidel odpovídá počtu výstupních funkcí příslušnosti.
- Výstupní funkce příslušnosti je konstantní nebo lineárního charakteru.
- Pravidla systému nejsou sdílená.

2.4.1.1. Architektura ANFIS

Architektura Jangova ANFIS obsahuje pět dopředně propojených vrstev FIS. Nejzákladnější architektura pracuje se dvěma vstupy x a y a jedním výstupem f . [4], [17], [39] a [41]. Vrstvy v architektuře mohou být adaptivní nebo neadaptivní. Aby se tyto vrstvy od sebe graficky rozlišily, jsou uzly v těchto vrstvách geometricky odlišné. Uvažujme tedy čtvercové uzly jako adaptivní a kruhové uzly jako neadaptivní. Schéma architektury ANFIS vykresluje Obr. 15 níže.



Obr. 15: Architektura ANFIS [4].

Bázi pravidel tohoto FIS typu Sugeno představují dvě IF-THEN pravidla v následujícím tvaru:

$$\begin{aligned} \text{IF } (x \text{ is } A_1) \text{ and } (y \text{ is } B_1) \text{ THEN } (f_1 = p_1x + q_1y + r_1) \\ \text{IF } (x \text{ is } A_2) \text{ and } (y \text{ is } B_2) \text{ THEN } (f_2 = p_2x + q_2y + r_2) \end{aligned}$$

1. vrstva: První vrstva architektury je adaptivní vrstva sloužící k fuzzifikaci vstupních proměnných. Každý uzel ve vrstvě představuje vstupní hodnotu jazykové proměnné. Funkce pro každý uzel v této vrstvě vypadá následovně:

$$O_i^1 = \mu_{A_i}(x). \quad (2.12.)$$

Kde:

μ_{A_i} je míra příslušnosti k jazykové hodnotě A_i

x je vstupní proměnná i -tého uzlu

2. vrstva: Druhá vrstva je tvořena čistě neadaptivními uzly, které mají za úkol mezi sebou pouze vynásobit vstupní signály z předchozí vrstvy. Každá výstupní hodnota jednotlivých uzlů pak reprezentuje váhu (sílu) použitého pravidla. Všechny uzly této vrstvy tedy můžeme chápat jako jedno IF-THEN pravidlo. Vzorec pro výpočet váhy pravidla je formulován takto:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y); \quad i = 1, 2. \quad (2.13.)$$

3. vrstva: Třetí vrstva ANFIS se také označuje jako normalizační vrstva. V této vrstvě získáváme poměr vah jednotlivých pravidel vzhledem k celkové sumě vah všech pravidel, tedy normalizovanou (relativní) váhu pravidla.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}; \quad i = 1, 2. \quad (2.14.)$$

Kde:

\bar{w}_i je normalizovaná váha pravidla,

w_i je váha (síla) pravidla.

4. vrstva: Čtvrtá vrstva ANFIS opět představuje adaptivní vrstvu systému, jejímž uzlům náleží funkce:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i); \quad i = 1, 2. \quad (2.15.)$$

Kde parametry p_i , q_i a r_i jsou parametry následujícího členu (konsekventu).

5. vrstva: Poslední a zároveň neadaptivní vrstva architektury počítá celkový výstup systému jako sumu výstupů z předchozí vrstvy.

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i}; \quad i = 1, 2. \quad (2.16.)$$

2.4.1.2. Hybridní učící algoritmus pro ANFIS

Nejběžnější učící algoritmus používaný pro síť ANFIS představuje hybridní algoritmus, tvořený kombinací metody LMS a BPG sestupné gradientní metody. Každá z těchto metod se zaměřuje na jinou část báze pravidel architektury ANFIS. Parametry antecedentu jsou upravovány pomocí BPG algoritmu a parametry konsekventu ve 4. vrstvě architektury pomocí metody nejmenších čtverců. Hybridní učící algoritmus můžeme takto rozdělit na dva chody, které se pravidelně opakují s každou iterací (epochou). Tyto chody se nazývají dopředný a zpětný chod [17], [49] a [60].

Tabulka 3: Popis dvou chodů hybridního algoritmu pro ANFIS [50].

	Dopředný chod	Zpětný chod
Parametry antecedentu	Pevně dané	Gradientní sestupné
Parametry konsekventu	Odhady nejmenšími čtverci	Pevně dané
Signály	Výstupy uzlů	Chybový signál

Dopředný chod

Dopředný chod obecně pracuje s LMS algoritmem, který slouží k identifikaci parametrů konsekventu. Na vstup ANFIS se přivedou tréninkové vzory, následuje postupný výpočet výstupů jednotlivých vrstev a posléze jsou identifikovány jednotlivé parametry konsekventu. Pro FIS typu Sugeno je výstupní vektor (označen \mathbf{C}) lineární funkce již ve známém tvaru (také viz vzorec 1.11):

$$\mathbf{C}_i = p_i x + q_i y + r_i. \quad (2.17.)$$

Předpokládáme-li tréninkovou množinu o velikosti m , můžeme sestavit m lineárních rovnic o parametrech p , q a r :

$$\left\{ \begin{array}{l} \mathbf{C}(1) = \bar{w}_1(1)f_1(1) + \dots \bar{w}_n(1)f_n(1) \\ \mathbf{C}(2) = \bar{w}_1(2)f_1(2) + \dots \bar{w}_n(2)f_n(2) \\ \mathbf{C}(m) = \bar{w}_1(m)f_1(m) + \dots \bar{w}_n(m)f_n(m) \end{array} \right\} \quad (2.18.)$$

Kde:

m je počet vstupně/výstupních učicích vzorů,
 n je počet uzlů v pravidlové vrstvě,
 x , y a \mathbf{C} jsou vstupně/výstupní vzory,

Další možný zápis lineárních rovnic vypadá takto:

$$\mathbf{C} = \mathbf{A} \cdot \mathbf{k}. \quad (2.19.)$$

Kde:

\mathbf{C} je výstupní vektor,

$$\mathbf{C} = \begin{bmatrix} \mathbf{C}(1) \\ \mathbf{C}(2) \\ \vdots \\ \mathbf{C}(m) \end{bmatrix}. \quad (2.20.)$$

\mathbf{A} je matice o velikosti $m \times n$,

$$\mathbf{A} = \begin{bmatrix} \bar{w}(1) & \bar{w}(1)x(1) & \bar{w}(1)y(1) & \dots & \bar{w}_n(1) & \bar{w}_n(1)x(1) & \bar{w}_n(1)y(1) \\ \bar{w}(2) & \bar{w}(2)x(2) & \bar{w}(2)y(2) & \dots & \bar{w}_n(2) & \bar{w}_n(2)x(2) & \bar{w}_n(2)y(2) \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ \bar{w}(m) & \bar{w}(m)x(m) & \bar{w}(m)y(m) & \dots & \bar{w}_n(m) & \bar{w}_n(m)x(m) & \bar{w}_n(m)y(m) \end{bmatrix}. \quad (2.21.)$$

\mathbf{k} je $n \times 1$ vektor neznámých parametrů konsekventu.

$$\mathbf{k} = [p_1 \quad q_1 \quad r_1 \quad \dots \quad p_n \quad q_n \quad r_n]. \quad (2.22.)$$

Pokud počet vstupně/výstupních vzorů m převyšuje nad počtem neznámých konsekventů n , hovoříme o tzv. přeúčeném problému. Takový problém nemusí mít žádné řešení, proto v tomto případě hledáme odhad k metodou LMS, který označujeme k^* . Tento odhad minimalizuje chybu $\|Ak - C\|^2$. Pro výpočet odhadu k^* slouží pseudo-inverzní metoda:

$$k^* = (A^T A)^{-1} A^T C. \quad (2.23.)$$

Kde:

A^T je transponovaná A ,

$(A^T A)^{-1} A^T$ je pseudoinverze A , je-li $(A^T A)$ nesingulární.

Jsou-li vypočteny všechny neznámé hodnoty konsekventu, lze vypočítat výsledný výstup ANFIS a jeho prostřednictvím chybový vektor:

$$e = C - C_{\text{Aktuální}}. \quad (2.24.)$$

Kde:

e je chybový vektor,

C je výstupní vzor,

$C_{\text{Aktuální}}$ je výsledný výstup ANFIS,

Zpětný chod

Ve zpětném chodu algoritmu se aplikuje BPG algoritmus. Vypočtený chybový signál z dopředného chodu je sítě distribuován zpět a pomocí řetězového pravidla (derivací složené funkce) se pozměňují parametry antecedentu. Bude-li funkce příslušnosti jednoho ze vstupních uzlů zvonová, výpočet změny parametru a se bude řetězové pravidlo rovnat (dle [17]):

$$\Delta a = -\eta \frac{\partial E}{\partial a} = -\mu \frac{\partial E}{\partial e} \times \frac{\partial e}{\partial C_{\text{Aktuální}}} \times \frac{\partial C_{\text{Aktuální}}}{\partial \bar{w}_i f_i} \times \frac{\partial \bar{w}_i f_i}{\partial \bar{w}_i} \times \frac{\partial \bar{w}_i}{\partial w_i} \times \frac{\partial w_i}{\partial w_{A_i}} \times \frac{\partial w_{A_i}}{\partial a}. \quad (2.25.)$$

Kde:

η je učicí koeficient,

E je momentální hodnota chyby pro výstupní ANFIS neuron.

Matematický zápis momentální hodnoty chyby pro výstupní ANFIS neuron vypadá takto:

$$E = \frac{1}{2} e^2 = \frac{1}{2} (C - C_{\text{Aktuální}})^2. \quad (2.26.)$$

Tudíž pro Δa také platí:

$$\Delta a = -\mu (C - C_{\text{Aktuální}}) (-1) f_1 \times \frac{\bar{w}_i (1 - \bar{w}_i)}{w_i} \times \frac{w_i}{w_{A_i}} \times \frac{\partial w_{A_i}}{\partial a}. \quad (2.27.)$$

Nebo:

$$\Delta a = -\mu (C - C_{\text{Aktuální}}) \cdot f_1 \bar{w}_i (1 - \bar{w}_i) \times \frac{1}{w_{A_i}} \times \frac{\partial w_{A_i}}{\partial a}. \quad (2.28.)$$

V případě zvonové funkce příslušnosti platí:

$$\frac{\partial w_{A_i}}{\partial a} = \frac{1}{\left[1 + \left(\frac{x-a}{c}\right)^{2b}\right]^2} \times \frac{1}{e^{2b}} \times 2b \times (x-a)^{2b-1} \times (-1) = w_{A_i}^2 \times \frac{2b}{c} \times \left(\frac{x-a}{c}\right)^{2b-1} \quad (2.29.)$$

Koeficienty b a c lze získat podobně.

2.4.1.3. Využití ANFIS pro extrakci fEKG

Metoda ANFIS v mnoha vědeckých člancích dokazuje, že je velmi účinným nástrojem pro filtraci nežádoucího šumu také v oblasti biomedicínských aplikací. Spousta z nich se detailně věnuje problematice extrakce fEKG. Jedním z článků, který potvrzuje efektivitu této hybridní metody při extrakci fEKG je článek C. K. S. Vijila et al. [2]. V tomto článku byla použita ANFIS s FIS typu Sugeno a hybridním učícím algoritmem. Architektura ANFIS byla opatřena dvěma vstupy, jedním výstupem a bází znalostí o celkem devíti pravidlech. Takto konstruovaná ANFIS se následně testovala jak na syntetických, tak na reálných datech. Reálná data byla vzorkována podle ANSI vzorkovací frekvencí 256Hz. Jelikož architektura ANFIS nelze příliš mnoho pozměňovat (typ FIS, počet vstupů, počet vrstev ANFIS atd.), nové výzkumy se zabývají zejména aplikací nových učících algoritmů pro trénování a kombinacemi ANFIS metody s jinými adaptivními/neadaptivními metodami. M. Nasiri et al. [6] se zaměřily na využití nových učících algoritmů a vytvořili ANFIS s učícím algoritmem, založeným na metodě PSO. Pro učení bylo použito PSO o 60 hejnech v prostoru učících parametrů (celkem 6). Výsledky extrakce fEKG takto naučené ANFIS se srovnaly s výsledky jiných metod, jako jsou metody založené na vlnkové transformaci, ICA algoritmu a ANFIS s hybridním učícím algoritmem. Srovnáním se došlo k závěru, že ANFIS trénované PSO je jako jediné ze srovnávaných metod schopno extrahovat všechny komponenty fEKG. Velkou výhodou navrženého ANFIS se také ukázala být vlastnost PSO neustrnout v lokálním minimu. Důkazem efektivitu této navržené metody je fakt, že se implementací PSO jako učícího algoritmu zabývá mnoho dalších článků, příkladem [51] a [52], které jsou blíže popsány již v kapitole 2.2.4. Článek R. V. Prasada [56] různými způsoby kombinuje ANFIS a metodu vlnkové transformace. Celkem bylo dosaženo eliminace mEKG třemi metodami: klasickou ANFIS s hybridním učícím algoritmem, předzpracováním signálu vlnkovou transformací následované ANFIS a ANFIS následované post processingem pomocí vlnkové transformace. Všechny tyto metody byly srovnány vzhledem k SNR (Signal to Noise Ratio), korelačním koeficientům a výkonovým indexům. Z výsledků se osvědčily metody samotné ANFIS a ANFIS s následným post processingem pomocí vlnkové transformace.

2.4.2. ANFIS realizace v Matlabu

Podstata ANFIS modelování a jeho učících algoritmů byla popsána již v kapitole 2.4.1. Tato kapitola se bude zabývat čistě rozšířením předchozí kapitoly o provedení praktické realizace ANFIS modelu v prostředí Matlab. Pro realizaci ANFIS modelu nejen v Matlabu, ale také v jiných softwarech (LabVIEW, atd. ...) je zapotřebí mít k dispozici vhodná vstupní a výstupní data, která se budou v síti trénovat. V našem případě se bude jednat o data syntetická i data reálná. Následně tvorba ANFIS modelu sleduje jednoduchou posloupnost úkonů [42]:

- I. Inicializace fuzzy systému: příkazy *genfis1* a *genfis2*.
- II. Definování parametrů pro učení sítě: počet opakování (iterací), tolerance chyb.
- III. Inicializace procesu učení: příkaz *anfis*. Proces učení trvá tak dlouho, dokud není dosaženo nastaveného počtu opakování nebo tolerance chyb.
- IV. Ověření správnosti výpočtu.

Všechny tyto kroky budou postupně popsány v následujících kapitolách pro prostředí Matlab. Zacyleno bude zejména na použití příkazu `anfis`, vzhledem k jeho využití v experimentální části této práce.

2.4.2.1. Inicializace fuzzy systému

Jak již bylo zmíněno v podkapitole 2.4.2, prvním krokem pro realizaci ANFIS je vytvoření fuzzy systému. Matlab ve své podpoře MathWorks nabízí celý set funkcí pro ANFIS modelování, jehož stěžejní součástí jsou funkce `genfis1` a `genfis2`. Obě tyto funkce slouží ke generaci vstupní struktury FIS. Každá z těchto funkcí ovšem dochází k výsledku prostřednictvím jiné metody [42].

Genfis1 generuje strukturu FIS typu Sugeno, která je využita jako počáteční podmínky pro trénování ANFIS. Učení sítě je zde realizováno mřížkovou selekcí (rozkladem) dat. Nejjednodušší zápis této funkce má tvar:

$$fismat = genfis1(data)$$

data v tomto případě označují matici tréninkových dat, přičemž všechny sloupce kromě posledního označují vstupní data a poslední sloupec data výstupní (stejná funkce jako *trnData*, popsáno níže). Chceme-li nastavit také počet vstupních funkcí příslušnosti, jejich typ a typ výstupní funkce příslušnosti, musíme příkaz patřičně rozšířit:

$$fismat = genfis1(data, numMFs, inmftype, outmftype)$$

numMFs je vektor, který umožňuje nastavení počtu funkcí příslušnosti spojených s každým vstupem. Pokud chceme dosáhnout stejného počtu funkcí příslušnosti pro každý vstup, stačí definovat *numMFs* jako jediné celé číslo.

inmftype zprostředkovává volbu typu vstupní funkce příslušnosti např. `trimf`, `trapmf`, `gbellmf`, `gaussmf`.

outmftype zprostředkovává volbu výstupní funkce příslušnosti. Podle pravidel pro tvorbu ANFIS viz výše, může být výstupní funkce příslušnosti pouze lineární (příkaz *linear*) nebo konstantní (příkaz *constant*).

Pokud použijeme zjednodušenou verzi příkazu, Matlab použije defaultně nastavené hodnoty, tzn. 2 vstupní funkce příslušnosti typu bell-shaped a lineární výstupní funkci příslušnosti.

Genfis2 generuje počáteční strukturu FIS typu Sugeno pomocí subtraktivního shlukování dat. Pro provedení této funkce je zapotřebí mít oddělená nastavení pro vstupní a výstupní data. Pokud má FIS pouze jeden výstup, je možné `genfis2` použít pro generaci počáteční FIS pro učení ANFIS. Toho lze dosáhnout tak, že se získá báze pravidel pomocí příkazu `subclust`. Tato funkce určí počet pravidel a počet funkcí příslušnosti pro atescendent. Základní zápis funkce `genfis2` v Matlabu:

$$fismat = genfis2(Xin, Xout, radii)$$

Kde:

Xin je matice vstupních dat,

Xout je matice výstupních dat.

radii je vektor, který specifikuje rozsah centrálního shluku. Zjistíme tak, kde všude centrální shluk ovlivňuje vstup a výstup FIS.

2.4.2.2. Popis příkazu *anfis*

Dalším krokem je při tvorbě ANFIS modelu vytvoření učícího algoritmu FIS modelu typu Takagi Sugeno. Toho nejjednodušeji dosáhneme pomocí příkazu:

$$fis = anfis(trnData)$$

Funkce *anfis* v tomto případě poskytuje hybridní algoritmus pro adaptaci parametrů FIS. Hybridní algoritmus je tvořen kombinací metody nejmenších čtverců (LMS) a gradientní metody zpětného šíření chyby (BPG). Příkaz *trnData* vytvoří matici z tréninkových dat. Pro FIS o N vstupech následně platí, že matice obsahuje $N + 1$ sloupců, kde prvních N sloupců tvoří vstupní data a poslední sloupec je vyhrazen pro výstupní data systému. Příkaz *fis* se dá dále rozšířit o další nastavení, kdy můžeme volit maximálně např.:

$$fis = anfis(trnData, initFIS, trnOpt, dispOpt, chkData, optMethod)$$

initFIS zprostředkovává inicializaci učení FIS = poskytuje počáteční nastavení funkcí příslušnosti pro učení. Může být specifikována takto:

Tabulka 4: Specifikace počátečního nastavení funkcí příslušnosti pro *initFIS*.

Specifikace	Popis funkce
Kladné celé číslo	Specifikuje počet funkcí příslušnosti pro všechny vstupy a generuje vstupní FIS pomocí <i>genfis1</i>
Vektor kladných celých čísel	Specifikuje počet funkcí příslušnosti pro každý vstup individuálně a generuje vstupní FIS pomocí <i>genfis1</i>

Pokud je FIS struktura generována pomocí *genfis1* nebo *genfis2* (tyto funkce budou v textu dále popsány) je nutné dodržovat následující pravidla:

- FIS je Takagi Sugeno model a musí být nultého nebo prvního řádu.
- FIS musí mít pouze jediný výstup.
- Funkce příslušnosti musí být stejného typu, výstupní funkce příslušnosti pouze lineární nebo konstantní.
- Všechna pravidla v síti musí mít stejnou váhu.

Není-li *initFIS* nijak specifikováno, je systému automaticky přiřazeno generování struktury FIS pomocí *genfis1*.

trnOpt vytvoří vektor pro specifikaci nastavení učení:

Tabulka 5: Způsoby nastavení *trnOpt*.

Specifikace	Popis funkce
trnOpt(1)	Nastavení počtu trénovacích iterací. Defaultní nastavení je 10.
trnOpt(2)	Chybová funkce s nastavenou hodnotou 0.
trnOpt(3)	Nastavení počátečního kroku. Defaultně nastaven krok 0.01.
trnOpt(4)	Zmenšení velikosti kroku. Defaultně 0.9
trnOpt(5)	Zvětšení velikosti kroku. Defaultně 1.1

dispOpt umožňuje zobrazit nastavení učení během samotného trénování sítě v Command Window.

Tabulka 6: Varianty nastavení *dispOpt*.

Specifikace	Popis funkce
dispOpt(1)	Zobrazí ANFIS informace= počet vstupních a výstupních funkcí příslušnosti
dispOpt(2)	Zobrazí chybové hodnoty
dispOpt(3)	Zobrazí velikost kroku každého aktualizovaného parametru
dispOpt(4)	Zobrazí konečné výsledky

Každou jednotlivou funkci lze zobrazit nebo ukrýt pomocí hodnot 1 a 0. Hodnota 1 danou funkci zobrazí, hodnota 0 funkci skryje.

chkData je funkce, která zabraňuje přeučení sítě. Tvoří ji skupina dat uložená do matice ve stejném formátu, v jakém jsou trénovací data.

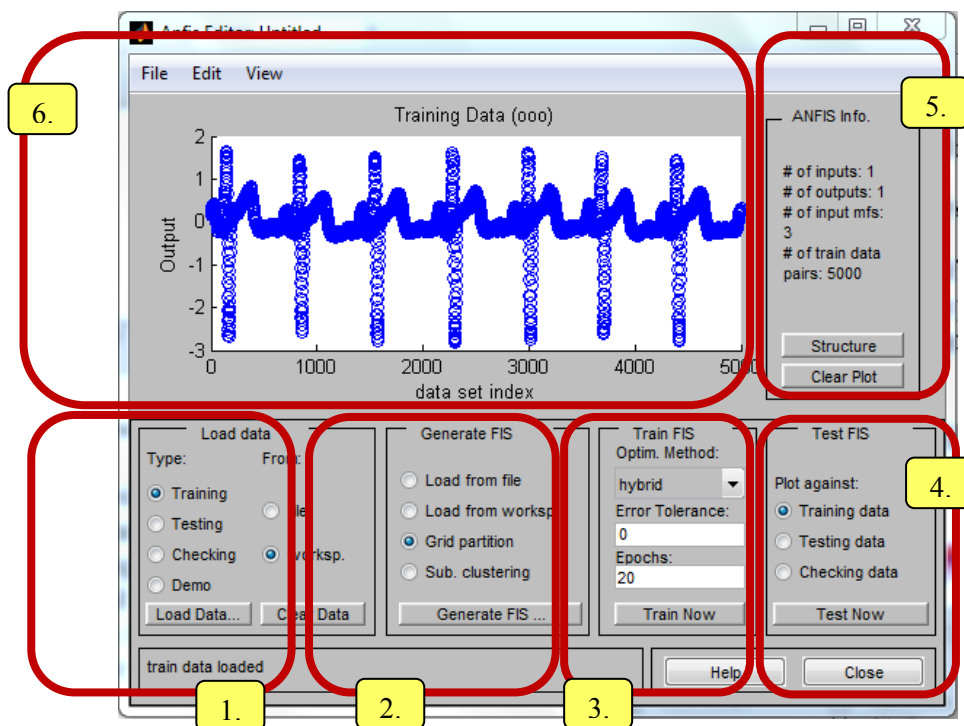
optMethod slouží k výběru učícího algoritmu sítě. Učící algoritmus je definován celými čísly následovně:

- Pokud je definován jako 1, je jako učící algoritmus použita hybridní metoda.
- Pokud je definován jako 0, je využit algoritmus zpětného šíření chyby.

Pokud není učící algoritmus definován, automaticky se pro FIS použije hybridní algoritmus.

2.4.2.3. Popis grafického prostředí ANFIS

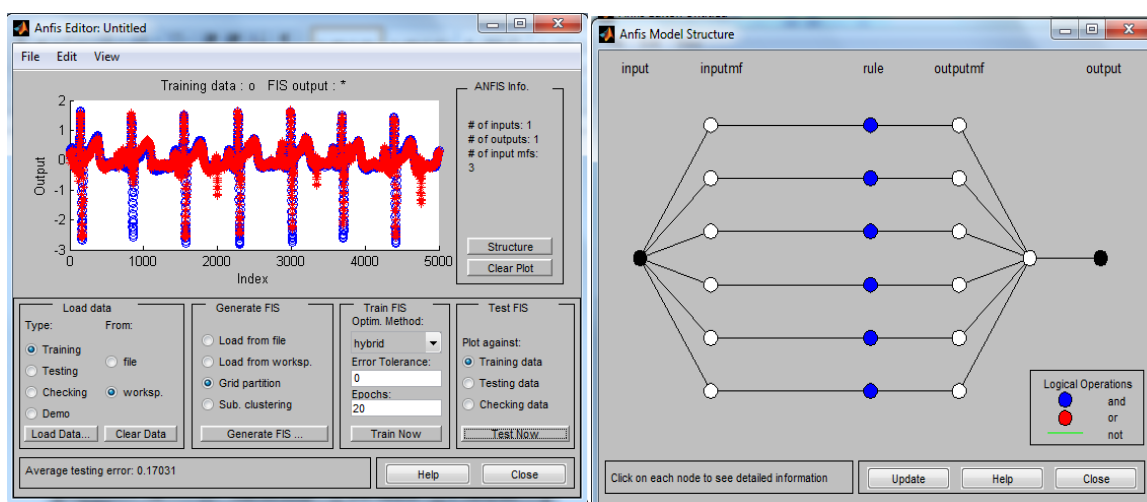
V prostředí Matlab existuje také interaktivní grafické prostředí pro zpracování ANFIS. Lze jej spustit pomocí příkazu *anfisedit*, zadaného do příkazového řádku Command Window. Otevře se ANFIS editor, ve kterém je možno měnit nastavení modelu (Obr. 16).



Obr. 16: ANFIS editor v Matlabu.

Editor je vizuálně rozdělen do několika částí. První z nich tvoří grafické okno pro vykreslení grafu. Další oddíly jsou pojmenovány takto:

- **Load data** – načte data pro trénování, testování, kontrolní data nebo demo data v automatické nabídce. Nabízí možnost načtení dat ze souboru nebo přímo z pracovní plochy. Důležité je pro načtení dat zvolit vhodný datový formát, podporovaný prostředím matlab. Načtená data se po kliknutí na tlačítko Load Data... automaticky zobrazí v grafu (viz Obr. 17), nebo se prostřednictvím tlačítka Clear Data... vymažou.
- **Generate FIS** – tento blok upravuje sestavení FIS modelu. Lze zvolit svůj vlastní FIS ze souboru nebo z pracovní plochy, nebo vytvořit nový metodou *genfis1* nebo *genfis2*. Při volbě FIS struktury se nesmí zapomenout označit způsob, jakým je zprostředkováno učení sítě. K dispozici je zde výběr učení buď mřížkovou selekcí, nebo subtraktivním shlukováním.
- **Train FIS** – se stará o učení FIS. Umožňuje výběr učicího algoritmu, tolerance chyb a počtu opakování.
- **Test FIS** – otestuje data v závislosti na trénovacích, testovacích a kontrolních datech. Tuto závislost vykreslí je do grafu.
- **ANFIS Info** – zobrazí informace k vytvořené struktuře ANFIS, jmenovitě počet vstupů a výstupů a počet vstupních účelových funkcí. Tlačítkem Structure se zobrazí grafická podoba struktury navrženého systému. Tlačítko Clear Plot smaže doposud posuzovaná data. Ukázka ANFIS architektury je nastíněna na Obr. 17 vpravo.



Obr. 17: Příklad vykreslení signálu v ANFIS editoru (vlevo). Architektura ANFIS v ANFIS editoru (vpravo).

PRAKTICKÁ ČÁST

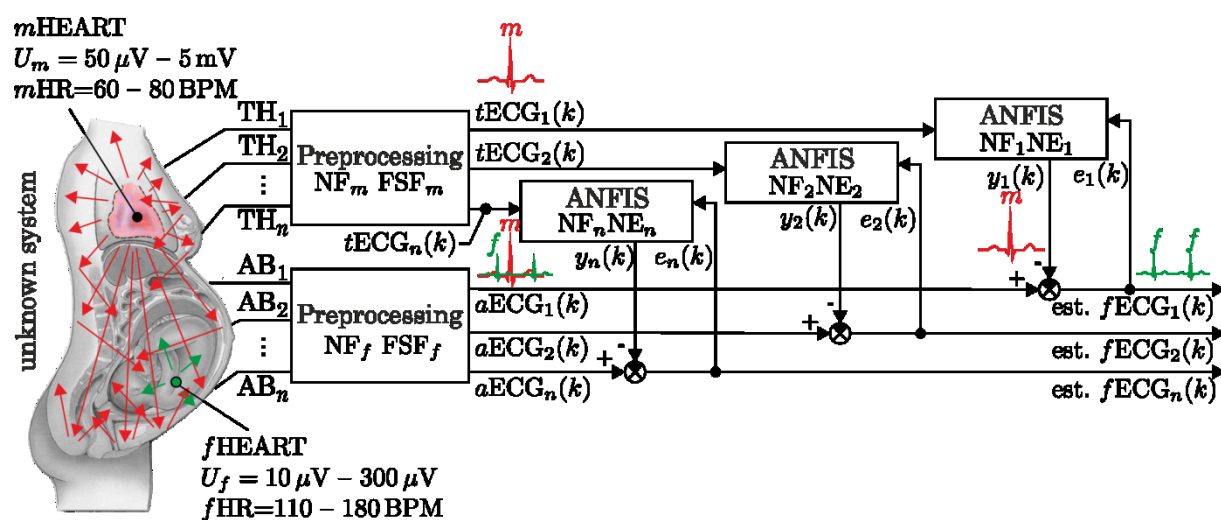
3. Návrh a softwarová realizace systému pro extrakci fEKG

Na základě rešerše v oblasti problematiky extrakce fEKG metodami soft computingu (viz Teoretická část) byla za ideální řešení zadání této diplomové práce zvolena metoda extrakce pomocí ANFIS. Pro adaptivní extrakci fEKG pomocí ANFIS jsou požadovány alespoň dva vstupní svody. Jeden vstupní signál představuje mEKG, tj. tEKG naměřené na hrudníku matky. Druhý vstupní signál je aEKG, které je tvořeno kompozicí mEKG a fEKG a měříme jej na abdomenu matky. Abdominální EKG zastává v systému roli referenčního signálu, kdežto tEKG je náš požadovaný signál.

3.1. Návrh systému pro extrakci fEKG

Na Obr. 18 je znázorněno schéma navrženého multikanálového adaptivního systému pro extrakci fEKG. Vstupy navrženého systému jsou dvojího charakteru (typu): torakální vstupy TH_1 - TH_n , které jsou měřeny multikanálovými svody v torakální oblasti na povrchu těla matky a abdominální vstupy AB_1 - AB_n , tvořené svody v oblasti abdomenu. Signál získaný z torakálních svodů koresponduje s reálným mEKG, kdežto signál z abdominálních svodů je sumací mEKG, fEKG a dalších nežádoucích šumů. Nutno podotknout, že mEKG naměřené na abdominálním svodu, přímo neodpovídá mEKG naměřenému na libovolném torakálním svodu. Jeho maximální výchylka je značně nižší a signál je zpožděný. Příčinou tohoto zkreslení je nelineární transformace signálu, způsobená průchodem signálu skrz tělo matky. Tuto transformaci nelze jednoznačně matematicky popsat.

Než se naměřené vstupní signály zpracují v ANFISu, provede se jejich preprocessing, aby se ze signálu odstranil nežádoucí šum v podobě 50 Hz rušení ze sítě, šumu z elektrických kontaktů, pohybových artefaktů a dalších rušení a signál se pro další zpracování digitalizuje. Nežádoucí frekvence ze signálu se eliminují prostřednictvím notch filtrů NF a selektivních frekvenčních filtrů FSF. Vzhledem k odlišnému charakteru vstupních signálů z torakálních a abdominálních elektrod, musí být preprocessingové bloky pro oba typy signálů nastaveny rozdílně tak, aby efektivně filtrovaly nežádoucí šumy. Předzpracované signály pak dále tvoří vstupy pro ANFIS adaptivní strukturu. Pro optimalizaci filtrace se v ANFIS struktuře modifikuje nastavení parametrů. To znamená počet a tvar účelových funkcí, počet epoch a učící algoritmus.



Obr. 18: Blokové schéma navrhovaného systému.

3.2. Metody hodnocení kvality filtrace plodového elektrokardiogramu

Metody hodnocení kvality extrakce fEKG se dají rozdělit na metody subjektivní a metody objektivní. Subjektivní metody hodnocení se zakládají na vizuálním posouzení filtrovaného signálu pouhým okem pozorovatele. Tyto metody nacházejí uplatnění zejména při hodnocení reálných signálů, u kterých není k dispozici referenční signál fEKG a nelze tak u nich uplatnit objektivní metody hodnocení. Objektivní hodnocení měření kvality extrakce fEKG je založeno na komparaci fEKG odhadnutého použitým adaptivním systémem a ideálního fEKG. Významné kritérium hodnocení kvality filtrace v tomto případě představuje míra absence nežádoucího šumu. Kvalitu filtrace fEKG z abdominálního měření a dobu potřebnou pro zpracování signálu výrazně ovlivňuje volba parametrů navrženého systému (vliv těchto parametrů na kvalitu filtrace je blíže popsán v kapitolách 4. a 5.). Aby bylo možné vliv jednotlivých parametrů posoudit nejen subjektivně, ale i objektivně, musí se kvalita filtrace fEKG zhodnotit pomocí relevantních matematických nástrojů. Prioritou je docílit úplné eliminace mEKG z fEKG signálu a to, pokud možno, v reálném čase. Evaluaci objektivně dosažených výsledků hodnocení kvality filtrace fEKG lze v ideálním případě dosáhnout optimálního nastavení adaptivního systému tak, aby byl schopen filtrace v reálném čase. V oblasti moderního signálového post-processingu se nejčastěji používají tři základní metody hodnocení kvality filtrace signálu, konkrétně odstup signálu od šumu (Signal to Noise Ratio- SNR), střední kvadratickou chybu (RMSE) a procentuální chybu (PRD). Tyto tři metody jsou využity v experimentální části této diplomové práce a na jejich základě jsou vyvozeny závěry o navrženém adaptivním filtračním systému. Z tohoto důvodu jsou v aplikaci na extrakci fEKG detailněji popsány níže v této kapitole.

3.2.1. Odstup signálu od šumu

Vztah mezi požadovaným signálem a nežádoucím šumem definuje SNR. Pro zhodnocení kvality filtrace pomocí SNR je nezbytné, aby byla předem známá hodnota SNR na vstupu a na výstupu systému, tzv. SNR_{in} a SNR_{out}. Na základě znalosti SNR_{in} a SNR_{out} se dá spočítat poměr signál/šum a jeho prostřednictvím sledovat progres ve filtraci signálu. Matematické vyjádření SNR_{in} a SNR_{out} popisují rovnice 3.1 a 3.2:

$$SNR_{in} = 10 \log_{10} \frac{\sum_{n=1}^{N-1} [sig_{org}(n)]^2}{\sum_{n=1}^{N-1} [sig_{ruš}(n) - sig_{org}(n)]^2}. \quad (3.1)$$

Kde:

sig_{org} je užitečný signál roven ideálnímu fEKG,

$sig_{ruš}$ je nežádoucí rušivý signál.

$sig_{ruš}$ odpovídá v námi navrženém systému součtu simulovaného (nebo reálného) mEKG po průchodu neznámým nelineárním prostředím lidského těla a požadovaného fEKG. Jelikož tento signál neobsahuje pouze nežádoucí mEKG, ale také požadovaný fEKG signál, musí se ve jmenovateli v rovnici 3.1 od sebe odečíst nežádoucí rušivý signál a ideální fEKG.

Výstupní SNR_{out} upravuje následující vztah [17]:

$$SNR_{out} = 10 \log_{10} \frac{\sum_{n=1}^{N-1} [sig_{org}(n)]^2}{\sum_{n=1}^{N-1} [sig_{predik}(n) - sig_{org}(n)]^2}. \quad (3.2)$$

Kde:

sig_{org} je užitečný signál roven ideálnímu fECG,
 sig_{predik} je predikovaný signál tvořící výstup adaptivního systému.

Stejně jako u výpočtu SNRin, je nutné od predikovaného signálu odečíst užitečný signál, aby se získal pouze vlastní šum obsažený v fEKG po zpracování adaptivním systémem.

3.2.2. Střední kvadratická chyba a relativní střední kvadratická chyba

Kvalitu predikce lze posuzovat také tzv. predikční chybou. Tato chyba reflektuje míru nepřesnosti mezi predikovaným a originálním výstupem. Relativní střední kvadratická chyba (RMSE) a jeho neodmocněná forma střední kvadratická chyba MSE mají široké využití v hodnocení predikce. MSE udává rozdíl mezi korespondujícími vzorky predikovaného a originálního signálu. Jeho matematická podoba je dána vztahem 3.3 [17].

$$MSE = \frac{1}{n} \sum_{i=1}^n \left(sig_{predik}(i) - sig_{org}(i) \right)^2. \quad (3.3)$$

Kde:

sig_{org} je užitečný signál roven ideálnímu fECG,
 sig_{predik} je predikovaný signál tvořící výstup adaptivního systému.

V praxi se daleko častěji používá jeho odmocněná podoba RMSE (viz rovnice 3.4 [17]). RMSE je použito pro hodnocení predikce také v této diplomové práci.

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n \left(sig_{predik}(i) - sig_{org}(i) \right)^2}. \quad (3.4)$$

RMSE rovněž udává míru difference mezi predikovaným a originálním signálem. Platí, že čím více se predikční chyba blíží nule, tím lépe predikovaný signál odpovídá původnímu signálu [62], [63].

3.2.3. Percentuální chyba

Percentuální chyba (PRD) patří mezi nejčastěji využívané hodnotící kriteria v oblasti fEKG. Vzorec 3. 5 [62] pro její výpočet je formulován následovně:

$$PRD = \sqrt{\frac{\sum_{i=1}^N [sig_{org}(i) - sig_{predik}(i)]^2}{\sum_{i=1}^N sig_{org}^2(i)}} \cdot 100. \quad (3.5)$$

Kde:

sig_{org} je užitečný signál roven ideálnímu fECG,
 sig_{predik} je predikovaný signál tvořící výstup adaptivního systému.

PRD porovnává sig_{org} a sig_{predik} . Prakticky se jedná o střední kvadratickou chybu (MSE) vztaženou k užitečnému signálu. Tímto PRD odstraňuje nedostatek MSE, kde signály s větší výchylnou mají rovněž vyšší chybu MSE, aniž by došlo k většímu zkreslení. Obecně platí, že čím více se blíží hodnota PRD k nule, tím podobnější jsou si oba porovnávané signály [62].

4. Ověření funkčnosti systému na syntetických i reálných datech

Ověření funkčnosti navrženého systému je provedeno na základě zhodnocení kvality filtrace. Jako nástroje pro hodnocení jsou použity objektivní metody hodnocení SNR, RMSE a PRD a také subjektivní hodnocení filtrace (u reálných signálů). Pomocí těchto hodnotících metod se v práci určilo, jaký vliv mají parametry adaptivního systému, jmenovitě tvar účelové funkce, počet epoch a počet účelových funkcí na kvalitu filtrace. Navrhovaný systém byl otestován celkem pro čtyři typy účelových funkcí, trojúhelníkovou, trapézovou, zvonovitou a gaussovu. Počet vyšetřovaných účelových funkcí se pohyboval vždy pro daný typ funkce od 2 do 9 v jednotlivých epochách. Jelikož změny v jednotlivých epochách nejsou tak markantní, v práci je používán systém s 10, 20 a maximálně 30 epochami. Tato nastavení korespondují s rychlostí filtrace a snahou docílit online filtrace. Větší počet epoch výrazně zvyšuje dobu filtrace s neúměrně nízkým zlepšením kvality filtrovaného signálu. Systém byl v této diplomové práci otestován na třech různých typech vstupních dat: na jednoduchých syntetických datech, vygenerovaných v prostředí Matlab, na složitějších syntetických datech generovaných sofistikovaným generátorem vytvořeným na Katedře kybernetiky a biomedicínského inženýrství a finálně na reálných datech.


4.1. Ověření funkčnosti systému na syntetických datech

4.1.1. Jednoduchá syntetická data

V této podkapitole bude popsán způsob generace jednoduchých syntetických dat, jejich charakter a efektivita filtrace ohodnocená prostřednictvím SNR, RMSE a PRD.

4.1.1.1. Popis jednoduchých syntetických dat

Jednoduché elektrokardiografické signály mEKG, fEKG a aEKG byly vytvořeny ve vývojovém prostředí Matlab podle zdrojového kódu, dostupného v [66]. U dat byla respektována fyziologie srdeční činnosti matky i plodu. Amplituda vytvořených signálů se pohybuje mezi 1-2 mV u mEKG a 0,1-0,5 mV u fEKG. Tepová frekvence matky je 85BPM, tepová frekvence plodu 132 BPM. Syntetické signály mEKG a fEKG představují ideální podobu signálů s nulovou izolinií, bez rušení a s pevnou amplitudou. Transformace signálu mEKG při průchodu neznámým prostředím těla matky v oblasti mezi hrudníkem a břišní stěnou se provedla prostřednictvím lineárního FIR filtru N-tého řádu. Průchodem signálu přes FIR filtr došlo ke zpoždění signálu v čase. Dále se amplituda posunutého signálu zmenšila o polovinu a byl k ní přidán náhodný šum o velikosti 0,02 mV. Tímto postupem byla vytvořena jednoduchá simulace transabdominální EKG.




Obr. 19: Vstupní jednoduché, syntetické signály systému.

Jelikož se FIR filtr řadí mezi lineární prvky, charakter zkreslení signálu je rovněž lineární. V simulaci je použit FIR filtr 20. řádu. Na Obr. 19 jsou znázorněna vygenerovaná jednoduchá syntetická data, na kterých je v práci demonstrováno hodnocení kvality filtrace fEKG. U vykreslených signálů je maximální výchylka mEKG rovna 1,2 mV, fEKG 0,2 mV a aEKG 0,6mV. V signálu aEKG jsou vyznačeny zřetelně viditelné výchylky fEKG. Ve srovnání s ideálním fEKG lze vidět, že ne všechny výchylky fEKG jsou v aEKG signálu zřetelné. Zejména v místech, kde se QRS komplex fEKG sčítá s QRS komplexem mEKG se výchylky fEKG nedají pouhým okem v signálu rozpoznat.

4.1.1.2. Hodnocení kvality filtrace jednoduchých syntetických dat

Nejprve bylo při hodnocení kvality filtrace hodnoceno SNR. Výsledky hodnocení filtrace pomocí SNR jsou vykresleny v Obr. 20.



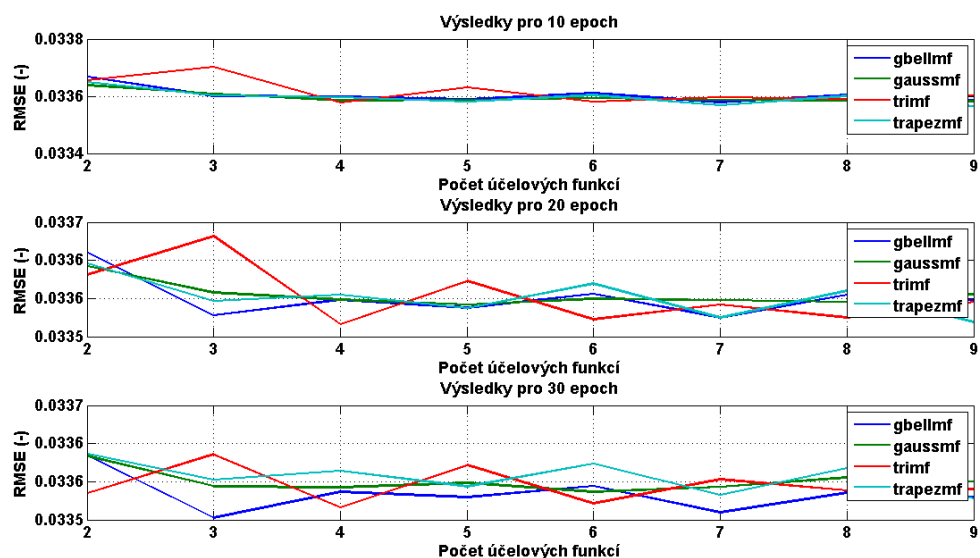
Obr. 20: Srovnání výsledků SNRout v závislosti na počtu účelových funkcí pro různé epochy.

Do Tabulka 7 jsou shrnuty výsledky filtrace fEKG pro jednoduchá syntetická data hodnocené na základě SNR_{out}. Z kapitoly 3.2.1 je zřejmé, že pro hodnocení musí být známá hodnota vstupního SNR_{in}. Ta byla vypočtena podle vztahu 3.1. Pro vybrané vstupní signály je vypočtená hodnota SNR_{in} = -8,6996 dB. Po filtraci se SNR zlepšilo v průměru o 8 dB. V tabulce je možné pozorovat, že se jednotlivé výsledné SNR_{out} prakticky nemění v závislosti na změně parametrů adaptivního systému. To můžeme přisuzovat jednoduchosti zpracovávaných dat, kdy se systém natrénuje nejlépe, již při nejmenším počtu účelových funkcí a bez ohledu na tvar funkce.

Tabulka 7: Výsledky filtrace fEKG pomocí SNR_{out} pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	SNR _{out} (dB)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézovitá funkce
10	2	-0,6909	-0,6936	-0,6899	-0,6926
10	3	-0,6898	-0,6863	-0,6894	-0,6910
10	4	-0,6810	-0,6830	-0,6801	-0,6811
10	5	-0,6797	-0,6797	-0,6795	-0,6802
10	6	-0,6793	-0,6798	-0,6788	-0,6797
10	7	-0,6786	-0,6787	-0,6786	-0,6786
10	8	-0,6780	-0,6775	-0,6782	-0,6782
10	9	-0,6779	-0,6775	-0,6773	-0,6779
20	2	-0,6922	-0,6938	-0,6902	-0,6912
20	3	-0,6895	-0,6864	-0,6894	-0,6894
20	4	-0,6818	-0,6842	-0,6805	-0,6792
20	5	-0,6808	-0,6810	-0,6795	-0,6795
20	6	-0,6799	-0,6809	-0,6789	-0,6780
20	7	-0,6798	-0,6800	-0,6789	-0,6779
20	8	-0,6792	-0,6786	-0,6783	-0,6773
20	9	-0,6773	-0,6790	-0,6761	-0,6772
30	2	-0,6865	-0,6896	-0,6888	-0,6911
30	3	-0,6808	-0,6845	-0,6877	-0,6906
30	4	-0,6760	-0,6831	-0,6791	-0,6801
30	5	-0,6747	-0,6800	-0,6776	-0,6805
30	6	-0,6742	-0,6799	-0,6774	-0,6785
30	7	-0,6739	-0,6791	-0,6775	-0,6790
30	8	-0,6733	-0,6774	-0,6758	-0,6784
30	9	-0,6717	-0,6781	-0,6748	-0,6783

Velikost predikční chyby RMSE se rovněž ve výsledcích filtrace prakticky nelišila v závislosti na nastavení parametrů adaptivního systému. Hodnota RMSE se pro dané signály pohybovala v průmětu okolo hodnoty RMSE=0,0336. Taková to hodnota RMSE se blíží směrem k nule, takže filtrace vstupního signálu by měla mít téměř nejvyšší možný efekt. V Obr. 21 lze pozorovat, že trojúhelníková účelová funkce o něco lépe filtruje signál při lichém počtu použitých účelových funkcí, kdežto ostatní funkce lépe pracují při použití sudého počtu účelových funkcí. Výsledky pro všechny variace nastavovaných parametrů jsou zaznamenány do Tabulka 8.



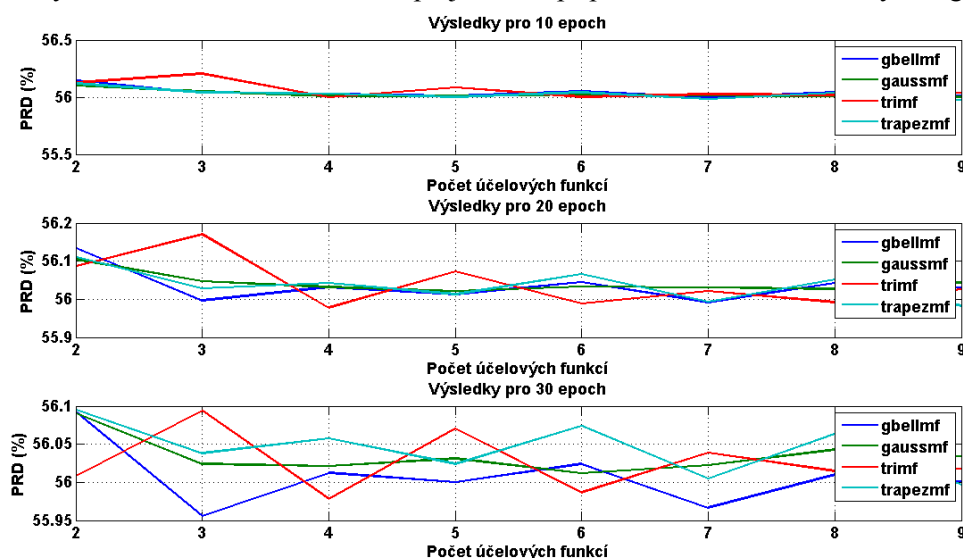
Obr. 21: Srovnání výsledků RMSE v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 8: Výsledky filtrace fEKG pomocí RMSE pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	RMSE (-)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	0,0337	0,0337	0,0336	0,0336
10	3	0,0336	0,0337	0,0336	0,0336
10	4	0,0336	0,0336	0,0336	0,0336
10	5	0,0336	0,0336	0,0336	0,0336
10	6	0,0336	0,0336	0,0336	0,0336
10	7	0,0336	0,0336	0,0336	0,0336
10	8	0,0336	0,0336	0,0336	0,0336
10	9	0,0336	0,0336	0,0336	0,0336
20	2	0,0337	0,0336	0,0336	0,0336
20	3	0,0336	0,0337	0,0336	0,0336
20	4	0,0336	0,0336	0,0336	0,0336
20	5	0,0336	0,0336	0,0336	0,0336
20	6	0,0336	0,0336	0,0336	0,0336
20	7	0,0336	0,0336	0,0336	0,0336
20	8	0,0336	0,0336	0,0336	0,0336
20	9	0,0336	0,0336	0,0336	0,0336
30	2	0,0336	0,0336	0,0336	0,0336
30	3	0,0336	0,0336	0,0336	0,0336
30	4	0,0336	0,0336	0,0336	0,0336
30	5	0,0336	0,0336	0,0336	0,0336
30	6	0,0336	0,0336	0,0336	0,0336
30	7	0,0336	0,0336	0,0336	0,0336
30	8	0,0336	0,0336	0,0336	0,0336
30	9	0,0336	0,0336	0,0336	0,0336

Přestože se hodnota RMSE výrazně přiblížila nule, výsledky hodnocení pomocí procentuální chyby PRD dosáhly v průměru 56% chyby predikce u libovolného použitého nastavení parametrů systému (viz Tabulka 9). PRD jako relevantnější hodnota je pro hodnocení kvality signálu

průkaznější. Dosažený výsledek, lze chápat jako následek lineárního zkreslení dat, na které se adaptivní systém na bázi ANFIS hůře adaptuje, než v případě nelineárně zkreslených signálů.




Obr. 22: Srovnání výsledků PRD v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 9: Výsledky filtrace fEKG pomocí PRD pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	PRD (%)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	56,1468	56,1254	56,0986	56,1175
10	3	56,0357	56,2045	56,0474	56,0392
10	4	56,0303	55,9975	56,0095	56,0288
10	5	56,0138	56,0848	56,0110	56,0022
10	6	56,0521	56,0024	56,0213	56,0414
10	7	55,9989	56,0270	56,0120	55,9814
10	8	56,0431	56,0175	56,0080	56,0366
10	9	56,0090	56,0369	56,0036	55,9759
20	2	56,1348	56,0864	56,1050	56,1105
20	3	55,9968	56,1704	56,0473	56,0281
20	4	56,0314	55,9776	56,0314	56,0423
20	5	56,0135	56,0723	56,0211	56,0128
20	6	56,0442	55,9881	56,0330	56,0663
20	7	55,9923	56,0209	56,0303	55,9927
20	8	56,0420	55,9925	56,0266	56,0512
20	9	56,0309	56,0262	56,0432	55,9828
30	2	56,0921	56,0082	56,0907	56,0950
30	3	55,9557	56,0942	56,0242	56,0381
30	4	56,0123	55,9784	56,0215	56,0575
30	5	56,0002	56,0708	56,0313	56,0241
30	6	56,0244	55,9868	56,0117	56,0737
30	7	55,9668	56,0389	56,0223	56,0047
30	8	56,0103	56,0146	56,0430	56,0637
30	9	56,0012	56,0176	56,0340	55,9969

Od typu a počtu použitých účelových funkcí a počtu epoch se odvíjí také výpočetní náročnost systému. Logicky vyplývá, že čím menší počet účelových funkcí a epoch, tím kratší čas filtrace.

Dále platí, že trojúhelníková a trapézová účelová funkce se natrénují rychleji, než funkce zvonová a gaussova (Tabulka 10, Obr. 23). Rychlost výpočtu kromě parametrů systému ovlivňuje také typ použitého procesoru v počítači.



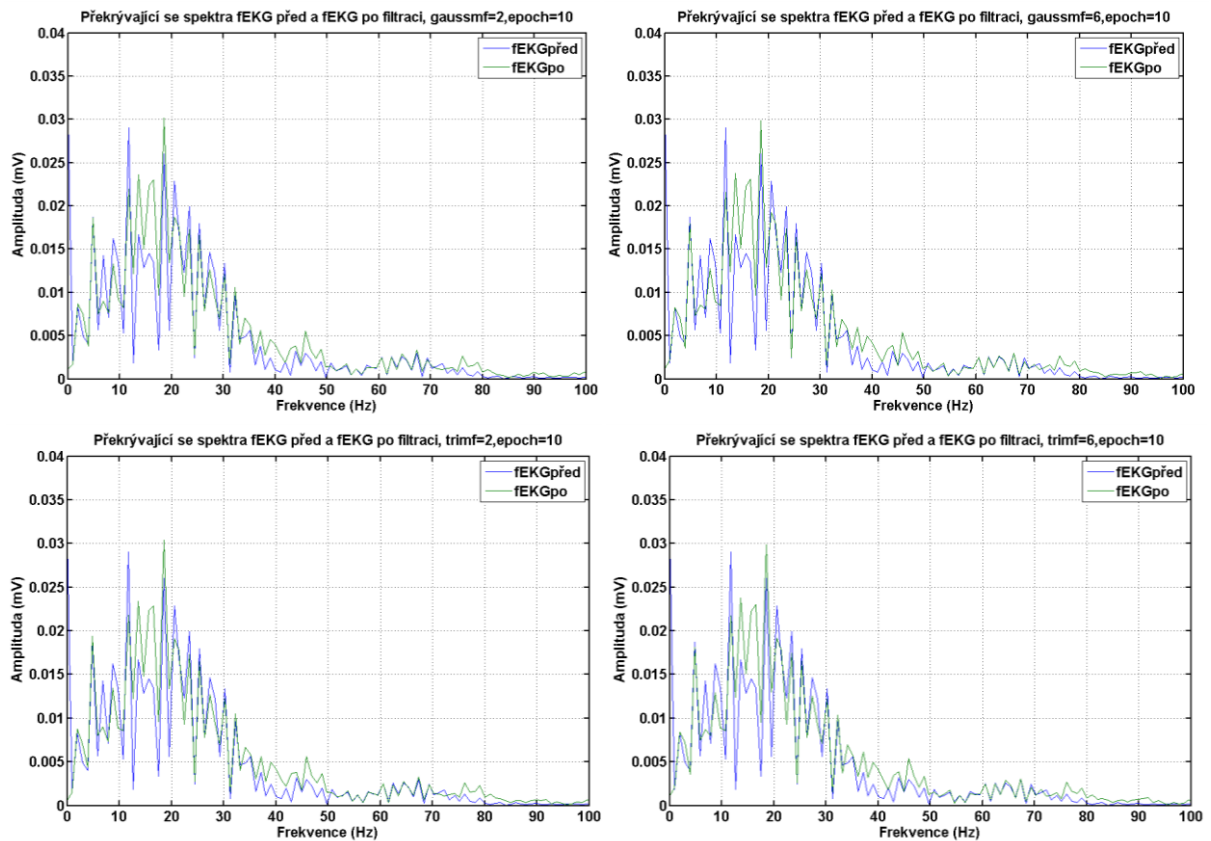
Obr. 23: Srovnání výpočetní náročnosti v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 10: Výpočetní náročnost filtrace pomocí ANFIS pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	Čas (s)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	4,0513	4,5970	3,3799	2,1672
10	3	15,5688	14,8514	12,2698	10,0245
10	4	15,5912	20,9188	12,3089	11,4112
10	5	51,2902	51,89151	39,0744	37,0060
10	6	48,6282	44,99954	40,3465	38,2891
10	7	44,4900	46,07692	41,8888	45,6560
10	8	45,9670	51,08506	44,3033	74,9261
10	9	63,2151	55,74597	46,0624	51,6731
20	2	8,5407	5,0155	9,4814	5,0011
20	3	19,8688	14,9076	15,8620	17,2387
20	4	59,0245	16,8881	23,0925	19,1700
20	5	110,2557	49,2989	52,5961	58,2339
20	6	179,2734	54,2449	54,2036	54,8543
20	7	91,2869	55,2175	53,1030	55,8850
20	8	97,4335	79,8416	58,9303	62,0602
20	9	93,8890	67,3879	76,0016	62,8164
30	2	9,3690	6,4749	15,3204	7,8612
30	3	19,1291	17,7597	31,4436	19,7681
30	4	23,8314	23,4981	36,5090	19,7074
30	5	57,0884	49,8172	88,6300	55,5928
30	6	59,3573	50,8543	57,4675	72,0235
30	7	65,4543	54,2969	75,4202	67,5118
30	8	82,4486	58,2774	82,8377	71,0136
30	9	134,9950	62,8652	90,7542	91,0636


Z dosažených výsledků filtrace není jasné, při jakých parametrech je systém nastaven nejlépe. Indikátorem pro použití konkrétního typu účelové funkce, jejich počtu a počtu epoch může

představovat pouze výpočetní náročnost řešení. V takovém případě by bylo vhodné použití jakékoliv účelové funkce při deseti epochách a počtu účelových funkcí rovnému dvěma. Na Obr. 24 jsou pro ilustraci vykreslena spektra pro gaussovu a trojúhelníkovou účelovou funkci.



Obr. 24: Ukázka amplitud spekter fEKG před a po filtraci.

Na základě grafického výstupu na Obr. 25 lze posoudit kvalitu filtrace také subjektivní metodou. Pro obrazový výstup bylo použito 6 gaussových účelových funkcí a 10 epoch. Vstupní $SNR_{in} = -8,699$ dB; výstupní $SNR_{out} = -0,6788$ dB, hodnota $RMSE = 0,0336$ a $PRD = 56,0141\%$. U extrahovaného signálu fEKG jsou v obrázku i po filtraci viditelné malé zákmitý, způsobené neúplným odfiltrováním QRS komplexu matky. Signál se dá i přes tyto zákmitý velmi dobře diagnosticky zhodnotit.

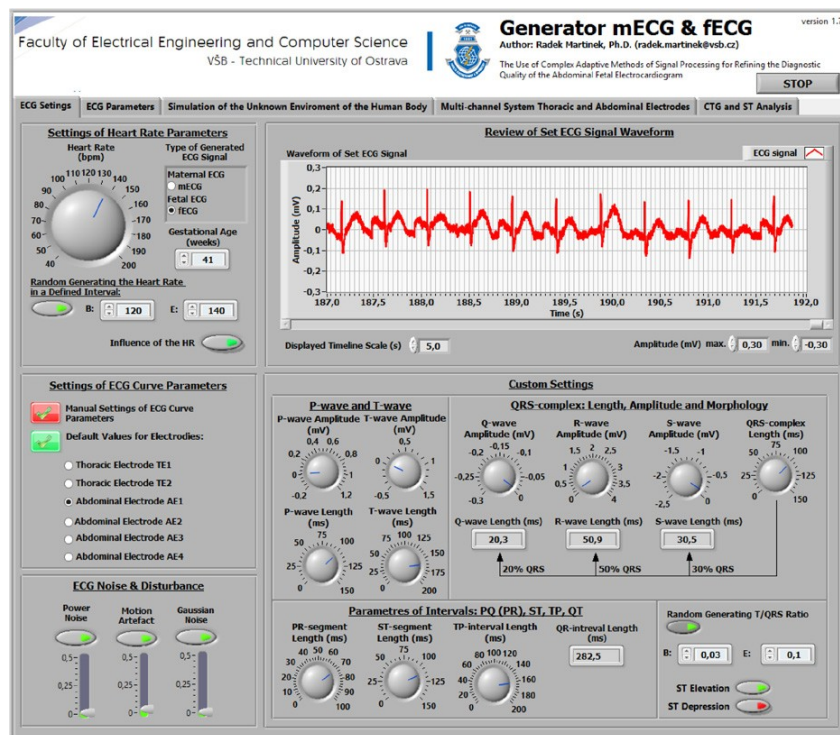


Obr. 25: Výstup z ANFIS.

4.1.2. Syntetická data generovaná sofistikovaným generátorem


4.1.2.1. Popis složitějších syntetických dat

Další skupinou testovaných dat tvoří data vytvořená v generátoru, vyvinutém na Katedře kybernetiky a biomedicínského inženýrství (generátor viz Obr. 26). Jedná se o vícekanálový generátor pro simulaci mateřského a plodového EKG. Generátor umožňuje nastavení mnoha parametrů včetně mateřské tepové frekvence (MHR), FHR, stáří plodu, biologických a technických artefaktů a simulace hypoxických stavů. Předností tohoto generátoru je zejména možnost generovat signály s definovanými vlastnostmi až pro 6 svodů (2 torakální a 4 abdominální svody). Data syntetická, vygenerovaná sofistikovaným generátorem slouží nejen v této práci k testování stávajících a nových neinvazivních metod zpracování a extrakce fEKG z abdomenu matky. Užitečnost generátoru spočívá ve znalosti referenčního fEKG, které poskytuje významnou zpětnou vazbu při supresi mEKG z transabdominálního EKG. S ohledem na referenční fEKG lze vyjádřit chyby predikce a hodnoty SNR. Simulace průchodu mEKG tělem matky je zprostředkována nelineární funkcí, která podstatně lépe koresponduje s reálnými záznamy aEKG, než dříve použitá transformace signálu pomocí FIR filtru u jednodušších syntetických dat v podkapitole 4.1.1. Právě nelinearita zkreslení dat předurčuje adaptivní systém na bázi ANFIS k lepším výsledkům filtrace, neboť ANFIS na nelineárních datech pracuje efektivněji než na datech lineárních. Podrobnější popis generátoru se nachází v [64]. Signály použité v této práci jsou uloženy do zvukového souboru ve formátu .wav a v této podobě dále použity v navržené SW realizaci adaptivního systému.



Obr. 26: Ukázka úvodní strany generátoru [64].


Referenční a vstupní signály systému jsou vykresleny na Obr. 27. Pro testování byly v této demonstraci použity signály pojmenované generovane_HE1.wav (mEKG), generovane_ideal_BE1.wav (referenční fEKG) a generovane_BE1.wav (naměřené aEKG). Maximální výchylka mEKG činí 1,6 mV a minimální výchylka mEKG je -2,8 mV. Maximální výchylka naměřeného aEKG dosahuje 1,1 mV a minimální výchylka -0,7 mV. U referenčního fEKG se maximální výchylka pohybuje na 0,5 mV a minimální výchylka na -0,5 mV. Tepová frekvence matky byla nastavena na 84 BPM a tepová frekvence plodu na 132 BPM, obdobně jako u jednoduchých syntetických dat.



Obr. 27: Referenční a vstupní data systému generovaná sofistikovaným generátorem.

4.1.2.2. Hodnocení kvality filtrace složitějších syntetických dat

Při hodnocení kvality filtrace pomocí SNR se ukázaly rozdíly v kvalitě filtrace při různém nastavení parametrů adaptivního systému. Vstupní odstup signálu od šumu byl roven $\text{SNR}_{\text{in}} = -7,4241$ dB, hodnoty SNR_{out} po filtraci variovaly pro použité signály v rozmezí mezi $\text{SNR}_{\text{out}} = -0,3525$ až $\text{SNR}_{\text{out}} = -0,0700$ dB. Z Obr. 28 lze graficky vyvodit, že zásadní roli v kvalitě filtrace hraje tvar a počet účelových funkcí. V případě našich vygenerovaných signálů bylo nejlepších výsledků dosaženo při použití gaussovy účelové funkce, nejhůře dopadla filtrace trapézovou účelovou funkcí. Adaptivní systém s gaussovou účelovou funkcí se rovněž nejrychleji natrénoval v závislosti na rostoucím počtu použitých účelových funkcí. Přijatelných hodnot SNR_{out} bylo při aplikaci gaussovy účelové funkce dosaženo již u tří účelových funkcí. Za použití trapézové účelové funkce se navržený systém natrénoval na přibližně stejnou hodnotu SNR_{out} až při aplikaci šesti účelových funkcí. Rozdíly v kvalitě filtrace mezi jednotlivými tvary funkcí se nepatrně stírají při použití vyššího počtu opakování (epoch). Je patrné, že použijeme-li pro natrénování systému 30 epoch, systém se natrénuje na přibližně stejnou hodnotu SNR_{out} , ať použijeme jakýkoliv typ účelové funkce. Otázkou však zůstává, do jaké míry je výhodné využití vyššího počtu epoch, neboť nastavení tohoto parametru nemá příliš významný vliv na zlepšení kvality filtrace signálu v poměru k výpočetní náročnosti. Nutno podotknout, že nastavení těchto parametrů pro filtrované signály je individuální a může se lišit v souvislosti s charakterem vstupních signálů. Na základě provedených experimentů ale můžeme tvrdit, že gaussova účelová funkce, představuje optimální tvar účelové funkce pro použití na filtraci fEKG.




Obr. 28: Srovnání výsledků SNR_{out} v závislosti na počtu účelových funkcí pro různé epochy.

V Tabulka 11 jsou doloženy výsledky hodnocení kvality filtrace pomocí SNR, které byly detailně popsány z Obr. 28 v textu výše.

Tabulka 11: Výsledky filtrace fEKG pomocí SNRout pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	SNR _{out} (dB)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	-0,0930	-0,3525	-0,1536	-0,0896
10	3	-0,1478	-0,1221	-0,0892	-0,2096
10	4	-0,0912	-0,0769	-0,0768	-0,1553
10	5	-0,0809	-0,0722	-0,0753	-0,1093
10	6	-0,0730	-0,0775	-0,0723	-0,0781
10	7	-0,0768	-0,0730	-0,0734	-0,0893
10	8	-0,0722	-0,0721	-0,0721	-0,0750
10	9	-0,0734	-0,0704	-0,0726	-0,0786
20	2	-0,0881	-0,3419	-0,1339	-0,0850
20	3	-0,1152	-0,1160	-0,0836	-0,1464
20	4	-0,0790	-0,0767	-0,0746	-0,1163
20	5	-0,0745	-0,0722	-0,0741	-0,0954
20	6	-0,0724	-0,0772	-0,0722	-0,0730
20	7	-0,0734	-0,0718	-0,0726	-0,0807
20	8	-0,0716	-0,0720	-0,0719	-0,0737
20	9	-0,0718	-0,0702	-0,0721	-0,0742
30	2	-0,0839	-0,3113	-0,1115	-0,0808
30	3	-0,0898	-0,1085	-0,0802	-0,1073
30	4	-0,0739	-0,0766	-0,0739	-0,0891
30	5	-0,0726	-0,0721	-0,0738	-0,0839
30	6	-0,0723	-0,0770	-0,0720	-0,0721
30	7	-0,0719	-0,0717	-0,0724	-0,0749
30	8	-0,0716	-0,0719	-0,0718	-0,0724
30	9	-0,0718	-0,0700	-0,0720	-0,0717

Hodnocení kvality filtrace pomocí RMSE v závislosti na nastavení parametrů adaptivního systému dosáhlo obdobných výsledků jako hodnocení prostřednictvím SNR. Neoptimálnějších hodnot predikční chyby docílil systém při trénování gaussovou a následně trojúhelníkovou účelovou funkcí, nejméně optimálních hodnot při trénování funkcí trapézovou. Hodnoty RMSE se pohybovaly mezi 0,0192 a 0,0122. (Tabulka 12 a na Obr. 29.)




Obr. 29: Srovnání výsledků RMSE v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 12: Výsledky filtrace fEKG pomocí RMSE pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	RMSE (-)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	0,0136	0,0259	0,0172	0,0135
10	3	0,0168	0,0162	0,0132	0,0192
10	4	0,0135	0,0124	0,0123	0,0179
10	5	0,0122	0,0123	0,0120	0,0137
10	6	0,0124	0,0124	0,0122	0,0134
10	7	0,0123	0,0122	0,0122	0,0128
10	8	0,0123	0,0122	0,0122	0,0128
10	9	0,0123	0,0124	0,0122	0,0126
20	2	0,0133	0,0255	0,0161	0,0132
20	3	0,0148	0,0156	0,0128	0,0154
20	4	0,0125	0,0124	0,0121	0,0153
20	5	0,0120	0,0123	0,0120	0,0129
20	6	0,0122	0,0124	0,0123	0,0127
20	7	0,0121	0,0122	0,0122	0,0123
20	8	0,0123	0,0122	0,0123	0,0126
20	9	0,0123	0,0124	0,0122	0,0124
30	2	0,0130	0,0244	0,0148	0,0129
30	3	0,0131	0,0148	0,0126	0,0141
30	4	0,0122	0,0123	0,0121	0,0134
30	5	0,0121	0,0124	0,0120	0,0125
30	6	0,0122	0,0124	0,0123	0,0126
30	7	0,0122	0,0122	0,0122	0,0121
30	8	0,0123	0,0122	0,0123	0,0125
30	9	0,0123	0,0124	0,0122	0,0124

Procentuální chyba predikce PRD, vyšla ve srovnání s jednoduchými syntetickými daty mnohem lépe. Při aplikaci šesti gaussových účelových funkcí a při 10 epochách se PRD rovnala 13,9940%. Zde se ukázal vliv, jaký má způsob transformace aEKG na účinnost použité filtrační metody. ANFIS si mnohem lépe poradil s nelineárně transformovaným signálem, než se signálem transformovaným lineárně pomocí FIR filtru v podkapitole 4.1.1.2. Výsledky jsou uloženy do Tabulka 13 a vykresleny v Obr. 30.




Obr. 30: Srovnání výsledků PRD v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 13: Výsledky filtrace fEKG pomocí PRD pro různý počet a typy účelových funkcí.

Počet epoch (-)	Počet účelových funkcí (-)	PRD (%)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	15,5725	29,6422	19,6680	15,4806
10	3	19,2071	18,4645	15,0811	22,0131
10	4	15,4256	14,1519	14,0151	20,5077
10	5	13,9311	14,0942	13,7597	15,6988
10	6	14,1387	14,2183	13,9940	15,3072
10	7	14,0545	13,9512	13,9316	14,6367
10	8	14,0646	14,0089	14,0036	14,6076
10	9	14,0544	14,1457	13,9948	14,4367
20	2	15,2321	29,1987	18,4472	15,1112
20	3	16,9437	17,9018	14,6439	17,5953
20	4	14,2721	14,1390	13,8015	17,5246
20	5	13,7072	14,1036	13,7632	14,8131
20	6	13,9454	14,2309	14,0135	14,5597
20	7	13,8738	13,9668	13,9436	14,0922
20	8	14,0377	13,9957	14,0141	14,4353
20	9	14,0171	14,1732	13,9930	14,2264
30	2	14,8291	27,9299	16,9726	14,7374
30	3	14,9654	16,9037	14,3738	16,1527
30	4	13,9289	14,1202	13,7850	15,3721
30	5	13,8915	14,1363	13,7740	14,2805
30	6	13,9380	14,2316	14,0423	14,4006
30	7	14,0009	13,9672	13,9695	13,8544
30	8	14,0164	13,9978	14,0203	14,3054
30	9	14,0155	14,1750	14,0026	14,2028

Výpočetní náročnost systému se zvyšovala s rostoucím počtem účelových funkcí a epoch. Z Obr. 31 a Tabulka 14 se ukázalo, že tvary funkcí, které se dokážou lépe adaptovat, mají vyšší nároky na výpočetní výkon počítače. Porovnáme-li výsledky filtrace prostřednictvím SNR, RMSE a PRD s náročností výpočtu, zjišťujeme, že využití vyššího počtu epoch vzhledem k přírůstku SNR a snížení RMSE a PRD, nemá příliš zásadní vliv na kvalitu filtrace signálu. Proto je v adaptivním systému dostačující použití deseti epoch k zajištění adekvátního výsledku filtrace.

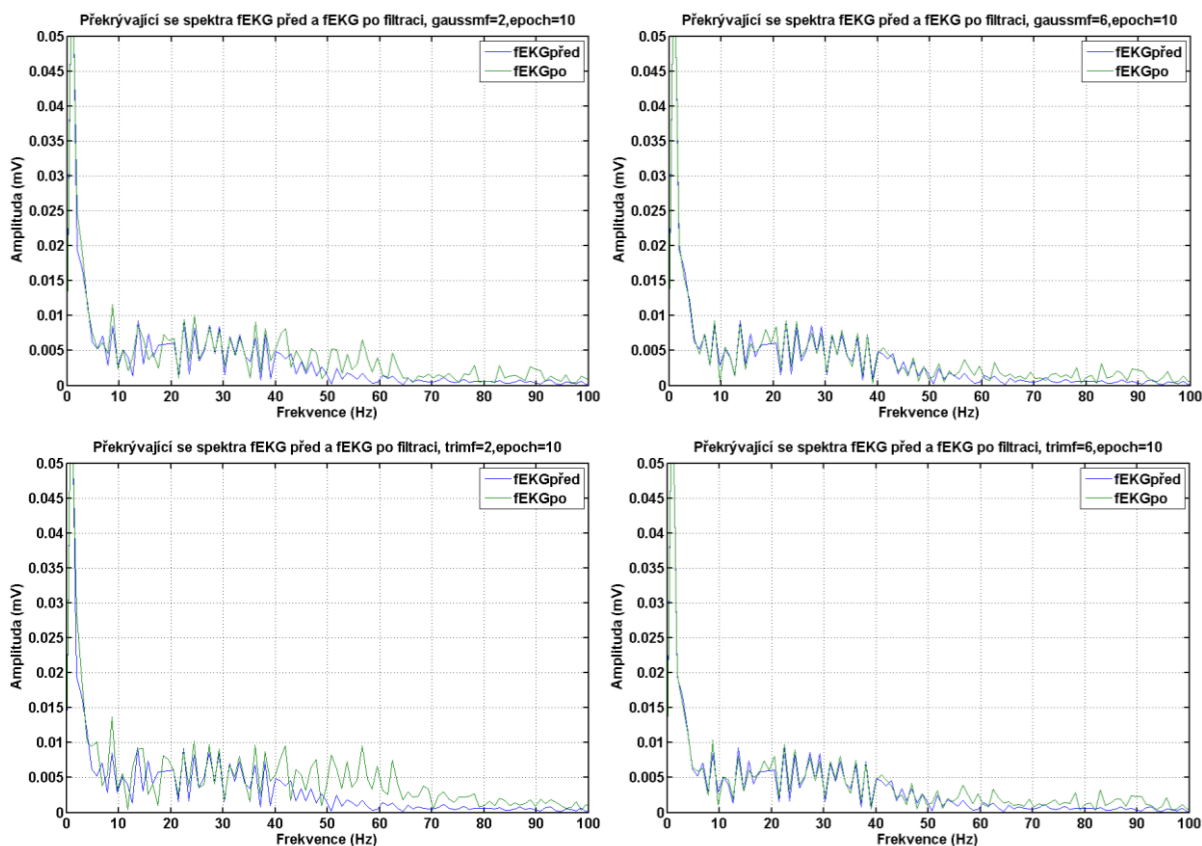


Obr. 31: Srovnání Výpočetní náročnosti v závislosti na počtu účelových funkcí pro různé epochy.

Tabulka 14: Výpočetní náročnost filtrace pomocí ANFIS pro různý počet a typy účelových funkcí.


Počet epoch (-)	Počet účelových funkcí (-)	Čas (s)			
		Zvonovitá funkce	Trojúhelníková funkce	Gaussova funkce	Trapézová funkce
10	2	7,1961	9,1948	8,2018	6,1964
10	3	25,4935	12,1935	17,4390	19,3949
10	4	28,5784	33,2342	21,9452	48,6762
10	5	85,3449	45,4221	52,4145	73,0387
10	6	85,7436	49,6105	83,1798	78,9942
10	7	76,7	47,6920	103,16	58,11
10	8	81,86	51,2373	89,56	112,29
10	9	78,93	70,1734	128,65	145,5
20	2	7,2023	7,3546	9,3418	10,1989
20	3	14,86	19,92	40,27	27,53
20	4	11,2016	38,59	29,72	40,85
20	5	77,06	102,58	74,22	205,61
20	6	55,84	76,34	89,04	88,81
20	7	59,68	64,54	78,42	69,65
20	8	65,66	75,2	81,79	166,9
20	9	137,9	67,66	90,34	162,94
30	2	12,1932	9,2017	19,93	10,1975
30	3	54,78	23,18	40,13	53,93
30	4	36,88	25,41	34,63	33,35
30	5	116,4	62,91	126,98	85,17
30	6	83,76	57,54	100,12	109,39
30	7	96,64	68,9	130,25	133,77
30	8	101,75	86,49	96,14	105,08
30	9	94,04	81,32	216,69	123,92

Spektra amplitud referenčního fEKG a výstupního fEKG z adaptivního systému jsou zobrazeny na Obr. 32. Opět jsou srovnány spektra nejefektivnějšího a nejméně efektivního tvaru účelové funkce v rámci filtrace fEKG. Zároveň se ve spektrech ukazuje vliv počtu použitých účelových funkcí na kvalitu filtrace.



Obr. 32: Ukázka amplitud spekter srovnávající referenční fEKG s výstupním fEKG po filtraci.

Obr. 33 znázorňuje výsledek filtrace pomocí navrženého adaptivního systému s neoptimálnějším nastavením parametrů systému. Neoptimálnějším nastavením parametrů je myšleno použití šesti gaussových účelových funkcí při deseti epochách. Parametry adaptivního systému byly voleny tak, aby bylo dosaženo co nejlepší kvality filtrace s přijatelnou náročností výpočtu. Na Obr. 31 můžeme vidět, že QRS komplex matky byl buď úplně eliminován, nebo minimalizován tak, aby jej nebylo možno mylně označit za QRS komplex plodu. V Obr. 33 jsou neúplně eliminované QRS komplexy matky vyznačeny v zeleném kruhu. Je zřetelné, že signál extrahovaného fEKG i po filtraci stále obsahuje šum (pravděpodobně 50 Hz ze sítě nebo šum vzniklý nesprávným přilnutím elektrody k bdomenu matky), který bude možno jednoduše odstranit pomocí adekvátních metod předzpracování. Z výsledného signálu lze snadno odečíst FHR plodu a po filtraci reziduálního šumu také ST segment. Výsledky filtrace na syntetických datech vytvořených generátorem tedy umožňují provedení ST analýzy na datech z neinvazivního abdominálního monitorování plodu. Pokud by se povedlo stejného výsledku dosáhnout také na reálných datech, znamenalo by to potenciál této adaptivní metody nahradit stávající invazivní metody monitorování za účelem diagnostiky hypoxie plodu a kontinuálního monitorování fEKG.



Obr. 33: Srovnání vstupního aEKG a referenčního fEKG s výstupem z ANFIS.

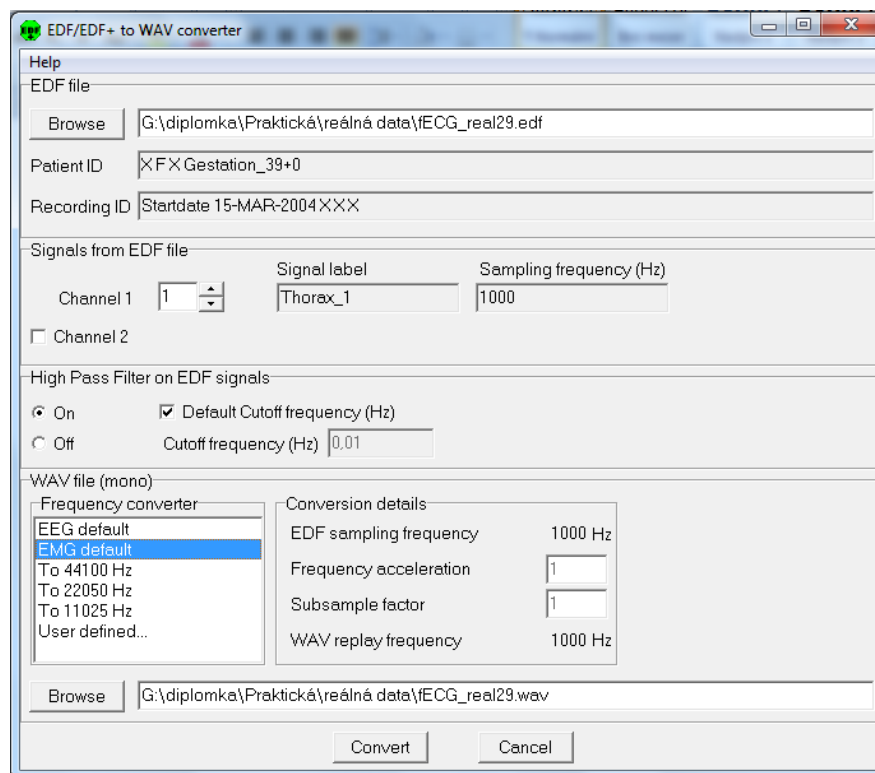
4.2. Ověření funkčnosti systému na reálných datech z klinické praxe

4.2.1. Popis reálných dat

Reálná data pro zpracování této diplomové části byla získána z databáze neinvazivních fEKG záznamů PhysioNet [65]. Tato databáze obsahuje sérii celkem 55 multikanálových neinvazivních fEKG záznamů z abdominálního měření, které zpravidla obsahují dva torakální a tři nebo čtyři abdominální signály. Všechny záznamy v databázi byly pořízeny u jedné pacientky v rozmezí mezi 21. a 40. týdnem těhotenství. Záznamy mají různou délku a byl pořizován alespoň jeden záznam týdně. Pozice elektrod se při každém záznamu měnila s cílem dosáhnout vyššího SNR. Při akvizici dat byl rovněž použit notch filtr pro eliminaci 50 Hz rušení ze sítě. Všechna nasnímaná data se ukládala do formátu .edf. Pro použití záznamů v prostředí Matlab bylo nutné takto uložené záznamy převést pomocí volně dostupného EDF/EDF+ to WAV konvertoru na zvukový záznam ve formátu .wav. Při převodu dat bylo nezbytné nastavení vhodné frekvenční konverze, tedy EDF vzorkovací frekvence a WAV přehrávací frekvence. Obě tyto frekvence byly pro konverzi dat nastaveny na hodnotu $f=1000$ Hz. Příklad převodu signálu je zobrazen na Obr. 34.

Z dostupné databáze bylo vybráno několik záznamů pro otestování adaptivního systému na reálných datech. Konkrétně se jednalo o záznamy fECG_real09.wav, fECG_real17.wav a fECG_real29.wav. Tyto záznamy byly pořízeny v 38., 39. a 40. týdnu těhotenství. Délka trvání záznamů je 5 min, 7 min a 33 min. Pro ověření účinnosti navržené adaptivní metody byly filtrovány záznamy o délce pouze 5s z důvodu menší výpočetní náročnosti. U použitých záznamů byly vždy použity signály z elektrod TH1 a AB1, které mají následující parametry:

- fECG_real17 má referenční hodnoty mEKG rovny $mEKG_{\max}=5$ mV; $mEKG_{\min}=-4$ mV a hodnoty filtrovaného signálu aEKG jsou $aEKG_{\max}=1$ mV a $aEKG_{\min}=-0,4$ mV; MHR=84BPM
- fECG_real29 má referenční hodnoty mEKG rovny $mEKG_{\max}=2$ mV; $mEKG_{\min}=-4$ mV a hodnoty filtrovaného signálu aEKG jsou $aEKG_{\max}=0,9$ mV a $aEKG_{\min}=-0,5$ mV; MHR=84BPM




Obr. 34: Prostředí EDF/EDF+ to WAV Convertor.

4.2.2. Hodnocení kvality filtrace reálných dat


Hodnocení výsledků filtrace objektivními metodami není v případě reálných dat možné z důvodu absence referenčního fEKG signálu. Proto jsou výsledky filtrace posuzovány pouze subjektivně vizuálním zhodnocením vykreslených signálů a amplitudových spekter. Toto subjektivní hodnocení může být na rozdíl od objektivních metod hodnocení filtrace do jisté míry zatíženo lidskou chybou, kdy pozorovatel špatně interpretuje dosažené výsledky a také individualitou hodnocení jednotlivých pozorovatelů. Nastavení parametrů adaptivního systému pro reálná data se inspirovalo v nejlepších dosažených výsledcích na složitějších syntetických datech. Všechna reálná vstupní data tedy byla trénována šesti gaussovými účelovými funkcemi v celkem deseti epochách.

Na Obr. 35 jsou prezentovány výsledky filtrace signálů ze záznamu fECG_real17.wav. Z vykresleného signálu extrahovaného fEKG, lze vidět, že adaptivní filtr dosáhl v supresi mEKG nízké účinnosti. QRS komplex matky se po průchodu adaptivním filtrem sice zúžil, ale jeho maximální výchylka se nesnížila. Naopak vlna T mateřského EKG byla systémem potlačena. Lze vidět, že QRS komplexy, na které byla superponovaná vlna T mateřského EKG, jsou v extrahovaném signálu zřetelnější. To je velmi pozitivní výsledek filtrace, který může jiným adaptivním algoritmům zaměřujícím se na detekci FHR podstatně zjednodušit práci.



Obr. 35: Výsledky filtrace pro signál fECG_real17.


O nepoznání horších výsledků bylo dosaženo také při filtraci signálů ze záznamu fECG_real29 (Obr. 36). V případě těchto dat nedošlo ani k úplnému potlačení vlny T mateřského signálu, jen se pouze zúžily a zvýraznily QRS komplexy mEKG.




Obr. 36: Výsledky filtrace pro signál fECG_real29.

Účinnost filtrace signálů byla dále posouzena vizuálně ze spekter vstupního filtrovaného signálu aEKG a výstupního signálu ze systému, tzv. extrahovaného fEKG (Obr. 37 a Obr. 38). Ty dokazují, že část amplitud mateřské komponenty se v extrahovaném fEKG zredukovaly na nižší hodnoty. Dané frekvence, u kterých došlo ke snížení hodnot spektra výstupního signálu, respektive extrahovaného fEKG frekvenčně odpovídají pásnu, kde se nachází hlavní část spektra vln P a T u mEKG. Toto pásmo má frekvenční rozmezí od 0 do 10 Hz [17]. Vykreslená spektra tedy

kořespondují s výsledky extrakce v Obr. 35 a Obr. 36. Porovnájí-li se spektra vykreslená pro signál ze záznamu fECG_real17 a fECG_real29 navzájem, lze vidět, že u signálu fECG_real17 došlo k výraznějšímu poklesu ve zmiňované části spektra než u signálu fECG_real29. Stejně závěry platí i v případě, je-li u totožných vstupních signálů použit různý počet účelových funkcí.



Obr. 37: Srovnání amplitud spekter na vstupu a výstupu systému pro záznam fECG_real17.



Obr. 38: Srovnání amplitud spekter na vstupu a výstupu pro záznam fECG_real29.

Nízká účinnost filtrace navrženého systému na použitých reálných byla očekávána. Na účinnosti filtrace reálných signálů pomocí ANFIS sehrála významnou roli kvalita záznamů, která nebyla pro experimenty zcela vhodná. Důvodů pro toto tvrzení je hned několik. Mezi tyto důvody patří např. fakt, že při akvizici dat nebyl brán zřetel na polohu plodu v děloze matky a s tím související rozmístění snímacích elektrod. Navíc se jedná o poměrně staré záznamy dat (rok 2013), které nesplňují atributy kvality dnešních abdominálních záznamů a metod předzpracování signálu. Právě tyto nedokonalosti snížily efektivitu filtrace pomocí ANFIS. Zvolená data byla vybrána vzhledem k omezenému počtu dostupných databází, které by shromažďovaly reálné, modelové a patologické záznamy fEKG. V tomto omezeném počtu databází přitom neexistuje jediná databáze, která by byla vhodná pro testování adaptivních metod filtrace. V návaznosti na tento nedostatek vyvíjí Katedra kybernetiky a biomedicínského inženýrství nový typ generátoru, který by mohl posloužit jako zdroj relevantních fEKG záznamů pro další experimenty s adaptivními metodami.

Z experimentů byl i přes nevhodná data vyvozen cenný poznatek v podobě eliminace T vlny a zúžení QRS komplexu mEKG, který může znamenat posun pro další výzkum v řešené problematice.

5. Srovnání vlastností vybraných soft computingových metod

Tato kapitola obsahuje souhrn všech získaných poznatků dosažených během zpracovávání experimentální části diplomové práce. V první podkapitole je věnována speciální pozornost vlivu změny nastavení parametrů ANFIS v navrženém adaptivním systému. V druhé podkapitole je srovnána úspěšnost filtrace na všech třech typech použitých dat.

5.1. Vliv nastavení parametrů ANFIS na kvalitu filtrace

Problematika správného nastavení ANFIS je poměrně neprobádanou oblastí výzkumu. Proto by výsledky této práce mohly přispět k významnému posunu v aplikaci ANFIS na zpracování fEKG. V práci byly měněny a kombinovány následující parametry ANFIS tak, aby bylo dosaženo optimálního nastavení systému:

- Tvar účelové funkce: zvonovitá, trapézová, trojúhelníková, Gaussova.
- Počet účelových funkcí: 2, 3, 4, ..., 9.
- Počet epoch: 10, 20 a 30.

Zásadní požadavky systému představuje jeho realizovatelnost a efektivita. Tyto požadavky jsou z hlediska optimálního nastavení parametrů systému podmíněny kvalitou filtrace a výpočetní náročností. Kvalita filtrace a výpočetní náročnost systému se neopírá pouze o správné nastavení jediného parametru, ale všech parametrů systému jako celku. Pro realizovatelnost systému tedy není vhodné použití příliš vysokého počtu účelových funkcí a epoch, které negativně ovlivňuje výpočetní náročnost systému, přičemž není dosaženo adekvátního zlepšení kvality filtrace. Právě z tohoto důvodu se tato diplomová práce omezila na testování systému maximálně pro devět účelových funkcí a třicet epoch.

Při testování nastavení parametrů ANFIS se došlo k rozdílným výsledkům v souvislosti s charakterem filtrovaných dat. Na kvalitu filtrace jednoduchých syntetických dat obsahujících lineární transformaci neměla změna parametrů prakticky žádný vliv. Tento výsledek je přisuzován právě jednoduchosti použitých dat, kdy systém dosáhl nejvyšší možné efektivity filtrace již při nejnižším možném počtu účelových funkcí a epoch. Naopak u složitějších syntetických nelineárně zkreslených dat generovaných sofistikovaným generátorem se vliv nastavení parametrů prokázal. Pro vytvoření správné analogie pro popsání efektu jednotlivých parametrů na filtraci signálu, je v textu nejprve popsán vliv tvaru účelové funkce, poté vliv počtu účelových funkcí a počet epoch a nakonec vliv všech těchto parametrů jako celku se zohledněním výpočetní náročnosti. Tvar účelové funkce představuje velice zajímavý parametr v oblasti filtrace fEKG. Ve všech autorem prostudovaných vědeckých článcích zabývajících se extrakcí fEKG pomocí ANFIS je vždy použito defaultní nastavení tvaru účelové funkce, tedy zvonovitá funkce. Ta sice vykazuje dobré výsledky, ale na základě testování kvality filtrace různými hodnotícími metodami v Kapitole 4 se jeví jako vhodnější varianta použití gaussovy účelové funkce. Nejhorší volbou pro filtraci fEKG je pak funkce trojúhelníková. U volby počtu účelových funkcí a epoch souhrnně platí v rámci zavedené limitace, že se zvyšujícím se počtem účelových funkcí a epoch roste kvalita extrahovaného fEKG. Nejhorší kvalitu filtrovaného signálu vykazovalo nastavení ANFIS při použití dvou trojúhelníkových účelových funkcí a při deseti epochách. Naproti tomu nejlepší výsledky byly dosaženy při použití devíti gaussových účelových funkcí a třiceti epoch. Vezme-li se ovšem v úvahu také výpočetní náročnost všech použitých kombinací parametrů, preference se posunou směrem k nižšímu počtu epoch a účelových funkcí. Optimální nastavení pro použitá data tak představovalo šest gaussových účelových funkcí při deseti epochách. Nutno podotknout, že toto

nastavení je optimální především pro data použitá v této diplomové práci. Je pravděpodobné, že se při použití vstupních signálů s jiným typem nelineární transformace optimální nastavení může nepatrně změnit. Vhodné nastavení parametrů ANFIS u reálných dat koresponduje s výsledky u dat složitějších syntetických, i když v jejich případě šlo pouze o subjektivní posouzení výsledků.

5.2. Srovnání úspěšnosti filtrace u všech typů použitých dat

5.2.1. Jednoduchá syntetická data

Ve srovnání kvality filtrace jednoduchých a složitějších syntetických dat dopadla lépe data složitější. To bylo způsobeno lineárním zkreslením aEKG u jednoduchých syntetických dat, na které se ANFIS hůře adaptuje, neboť je určen pro adaptaci na nelineární data. Pro filtraci lineárně zkreslených signálů je proto vhodnější použití adaptivních algoritmů, které jsou pro adaptaci na lineární data uzpůsobeny. Příkladem takového algoritmu může být například kombinace FIR filtru s LMS a RLS, který na tomto typu dat úspěšně otestovala kolegyně Bc. Radana Kahánková ve své diplomové práci *Adaptivní metody extrakce plodového elektrokardiogramu*. Z SC metod by se ve filtraci jednoduchých syntetických dat lépe uplatnily lineární SC metody založené na algoritmu ADALINE nebo MADALINE.

5.2.2. Složitější syntetická data

Filtrace složitějších syntetických dat obsahující nelineární zkreslení aEKG přinesla poměrně uspokojivé výsledky. Rušivý QRS komplex mEKG sice nebyl v datech úplně eliminován, ale nijak neovlivňoval správnou diagnostiku QRS komplexů fEKG. Jelikož se charakter těchto syntetických signálů blíží charakteru současných reálně získávaných dat, ukazují výsledky filtrace, že použití adaptivních metod založených na ANFIS má potenciál se do budoucna rozvíjet v extrakci reálného fEKG. Dalšího zlepšení kvality filtrace by se mohlo docílit například kombinací metody ANFIS s metodou slepé separace signálu, která lépe potlačuje QRS komplexy mEKG.

5.2.3. Reálná data

Na reálných datech byl navržený systém mnohem méně účinný než na složitějších syntetických datech. Přesto je z výsledků patrné, že došlo k potlačení T vlny a zúžení QRS komplexu mateřského EKG. Stejně jako u předchozích dat stojí za zvážení kombinace navrženého systému s dalšími adaptivními metodami lépe potlačujícími QRS komplex matky.

6. Diskuze dosažených výsledků

Zhodnotí-li se závěry z předchozích kapitol experimentální části, lze říci, že navržený adaptivní systém přispívá ke zlepšení výsledků extrakce fEKG. Pro jeho správnou funkci je ale zapotřebí zajištění vhodného nastavení parametrů ANFIS a předzpracování signálu. Pokud by ze vstupních signálů například nebylo odstraněno 50 Hz rušení ze sítě prostřednictvím notch filtru, negativně by to ovlivnilo výsledky filtrace. Důležitou roli hraje také povaha zkreslení dat (ANFIS se lépe natrénuje na nelineárních než lineárních datech), umístění snímacích elektrod při reálném abdominálním měření a pozice plodu v děloze matky, tak aby už před samotnou filtrací bylo dosaženo co nejlepšího SNR. Na syntetických i reálných datech se dalo pozorovat, že QRS komplex není ani v jednom případě aplikace úplně eliminován. Proto by bylo vhodné zkombinovat ANFIS s jinými adaptivními metodami potlačujícími QRS komplex matky a měnit jejich sled při filtraci, aby se dosáhlo lepších výsledků filtrace.

V návaznosti na načtenou literaturu by se pro budoucí výzkum mohla zvážit kombinace metody ANFIS s PSO nebo genetickými algoritmy, které zabraňují algoritmu v ustrnutí v lokálním maximu (popř. minimu) a které by mohly přispět k extrakci celého plodového PQRSTU komplexu. Vzhledem k nedostatku Gold Standard záznamů fEKG je také nasnadě pokusit se vytvořit syntetické záznamy, odpovídající charakteru reálných záznamů. O vytvoření generátoru takovýchto signálů se snaží třeba vědecký tým Katedry kybernetiky a biomedicínského inženýrství na Fakultě elektrotechniky a informatiky Vysoké školy báňské – Technické univerzity Ostrava.

Závěr

Jádrem této diplomové práce bylo vytvoření softwarové realizace systému pro extrakci fEKG metodami soft computingu a jeho ověření na syntetických a reálných datech. Ze znalostí získaných z rozsáhlé rešerše současného stavu řešené problematiky byla za nejvhodnější použitelnou SC metodu pro tuto realizaci zvolena metoda ANFIS, ve které se snoubí přednosti hned dvou SC metod: fuzzy logiky a neuronových sítí. Tento navržený systém na bázi ANFIS se otestoval hned na třech typech vstupních dat. Důraz byl kladen na nastavení parametrů ANFIS a s ním související kvalitu filtrace a výpočetní náročnost.

Přínos této diplomové práce představuje evaluace nastavení parametrů ANFIS s cílem dosažení, co nejvyšší kvality filtrace, kdy bylo zjištěno, že za optimální nastavení lze považovat použití šesti gaussových účelových funkcí s deseti epochami (opakováními). Toto zjištění v budoucnu napomůže ke zkvalitnění filtrace fEKG v dalších navazujících pracích, které se budou extrakcí fEKG zabývat.

Za úspěch lze v případě posouzení kvality filtrace na třech různých typech vstupních dat považovat zjištění, že u reálných vstupních dat dojde při filtraci metodou ANFIS ke snížení nebo úplné redukci vln T mateřského EKG a k zúžení jeho QRS komplexů. QRS komplexy plodového EKG se v těchto oblastech naopak zvýrazní. Vzhledem k faktu, že tato diplomová práce je dílčím blokem komplexnějšího výzkumného celku, budou se další části výzkumu pravděpodobně věnovat metodám vhodným pro potlačení úzkého mateřského QRS komplexu (např. metoda slepé segmentace signálu) a kombinacím těchto adaptivních metod s metodou ANFIS tak, aby došlo k úplnému potlačení mateřské komponenty v abdominálním signálu.

Použitá literatura

- [1] BIN IBNE REAZ, M. a LEE SZE WEI. Adaptive linear neural network filter for fetal ECG extraction. *International Conference on Intelligent Sensing and Information Processing, 2004. Proceedings of.* IEEE, 2004, : 321-324. DOI: 10.1109/ICISIP.2004.1287675. ISBN 0-7803-8243-9. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1287675>
- [2] KEZI SELVA VIJILA, C., P. KANAGASABAPATHY a S. JOHNSON. Adaptive Neuro Fuzzy Inference System for Extraction of fECG. *2005 Annual IEEE India Conference - Indicon.* IEEE, 2005, : 224-227. DOI: 10.1109/INDCON.2005.1590160. ISBN 0-7803-9503-4. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1590160>
- [3] ANOOP, Saladi S. V. K. K., Ch. Midhun PRABHU a Sunil Kumar PENUMALA. Detection of QRS Complex of Fetal ECG Using Biologically Inspired Soft-Computing Tools. *2009 Annual IEEE India Conference.* IEEE, 2009, : 1-4. DOI: 10.1109/INDCON.2009.5409366. ISBN 978-1-4244-4858-6. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5409366>
- [4] ASSALEH, Khaled. Extraction of Fetal Electrocardiogram Using Adaptive Neuro-Fuzzy Inference Systems. *IEEE Transactions on Biomedical Engineering.* 2007, 54(1): 59-68. DOI: 10.1109/TBME.2006.883728. ISSN 0018-9294. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4034004> **citováno 39x**
- [5] HASAN, M. A., M. B. I. REAZ, M. I. IBRAHIMY, M. S. HUSSAIN a J. UDDIN. Detection and Processing Techniques of FECG Signal for Fetal Monitoring. *Biological Procedures Online.* 2009, 11(1): 263-295. DOI: 10.1007/s12575-009-9006-z. ISSN 1480-9222. Dostupné také z: <http://www.biologicalproceduresonline.com/content/11/1/263> **citováno 25x**
- [6] NASIRI, Maryam. Fetal Electrocardiogram Signal Extraction by ANFIS Trained with PSO Method. *International Journal of Electrical and Computer Engineering (IJECE).* 2012, 2(2). DOI: 10.11591/ijece.v2i2.231. ISSN 2088-8708.
- [7] CAMPS-VALLS, Gustavo, Marcelino MARTÍNEZ-SOBER, Emilio SORIA-OLIVAS, Rafael MAGDALENA-BENEDITO, Javier CALPE-MARAVILLA a Juan GUERRERO-MARTÍNEZ. Foetal ECG recovery using dynamic neural networks. *Artificial Intelligence in Medicine.* 2004, 31(3): 197-209. DOI: 10.1016/j.artmed.2004.03.005. ISSN 09333657. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0933365704000508>
- [8] WANG, Peizhuang a Shaohua TAN. Soft computing and fuzzy logic. *Soft Computing - A Fusion of Foundations, Methodologies and Applications.* 1997-4-9, 1(1): 35-41. DOI: 10.1007/s0050000050004. ISSN 1432-7643. Dostupné také z: <http://link.springer.com/10.1007/s0050000050004>
- [9] POLI, Riccardo, James KENNEDY a Tim BLACKWELL. Particle swarm optimization. *Swarm Intelligence.* 2007, 1(1): 33-57. DOI: 10.1007/s11721-007-0002-0. ISSN 1935-3812. Dostupné také z: <http://link.springer.com/10.1007/s11721-007-0002-0>

- [10] NASIRI, Maryam. Fetal Electrocardiogram Signal Extraction by ANFIS Trained with PSO Method. *International Journal of Electrical and Computer Engineering (IJECE)*. 2012, **2**(2). DOI: 10.11591/ijece.v2i2.231. ISSN 2088-8708.
- [11] VIJILA, C.K.S., S. RENGANATHAN a S. JOHNSON. Suppression of maternal ECG from fetal ECG using neuro fuzzy logic technique. *Proceedings of the International Joint Conference on Neural Networks, 2003*. IEEE, 2003, : 1007-1012. DOI: 10.1109/IJCNN.2003.1223828. ISBN 0-7803-7898-9. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1223828>
- [12] WIDROW, B. a R. WINTER. Neural nets for adaptive filtering and adaptive pattern recognition. *Computer*. 1988, **21**(3): 25-39. DOI: 10.1109/2.29. ISSN 0018-9162. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=29>
- [13] VIJILA, C. Kezi Selva, M.E., P. KANAGASABAPATHY a Stanley JOHNSON. Fetal ECG Extraction using Softcomputing Technique. *Journal of Applied Sciences*. 2006, **6**(2): 251-256. DOI: 10.3923/jas.2006.251.256. ISSN 1812-5654. Dostupné také z: <http://www.docsdribe.com/pdfs/ansinet/jas/2006/251-256.pdf>
- [14] SPOONER ., Jeffrey T.. *Stable adaptive control and estimation for nonlinear systems: neural and fuzzy approximator techniques* [online]. Hoboken, NJ: Wiley-Interscience, 2002 [cit. 2015-08-05]. ISBN 978-047-1221-135.
- [15] HASAN, Muhammad Asraful a Md MAMUN. BPNN based MEGC elimination from the abdominal signal to extract fetal signal for continuous fetal monitoring. *Acta Scientiarum. Technology* [online]. 2013, **35**(2): - [cit. 2015-08-14]. DOI: 10.4025/actascitechnol.v35i2.15361. ISSN 1807-8664. Dostupné z: <http://periodicos.uem.br/ojs/index.php/ActaSciTechnol/article/view/15361>
- [16] VILIJA, C.Kezi Selva, P. KANAGASABAPATHY a Ebbie Selva KUMAR. A SURVEY OF INTERFERENCE CANCELLATION IN BIOSIGNALS. *International Journal of Reviews in Computing*. 2011, : 20. ISSN 2076-3328. Dostupné také z: <http://www.ijric.org/volumes/Vol7/Vol7No7.pdf>
- [17] MARTINEK, Radek. *The Use of complex adaptive methods of signal processingfor refining the diagnostic quality of the abdominalů fetal cardiogram*. Ostrava, 2014. Disertační práce. Vysoká škola báňská - Technická univerzita Ostrava. Vedoucí práce Jan Žídek.
- [18] TUČKOVÁ, Jana. *Chosen applications of artificial neural networks in signal processing*. Vyd. 1. Praha: České vysoké učení technické v Praze, 2009, 224 s. ISBN 978-80-01-04229-8.
- [19] WIDROW, B. a R. WINTER. Neural nets for adaptive filtering and adaptive pattern recognition. *Computer*. 1988, **21**(3): 25-39. DOI: 10.1109/2.29. ISSN 0018-9162. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=29>
- [20] VOLNÁ, Eva. OSTRAVSKÁ UNIVERZITA. *Neuron networks 1*. 2. Ostrava: Ostravská univerzita v Ostravě, 2008. Dostupné také z: http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf

- [21] POKORNÝ, Miroslav a Vilém SROVNAL. *Systems with artificial intelligence*. První. Ostrava: VŠB-TU Ostrava, 2012. CZ.1.07/2.2.00/15.0113. Dostupné také z: <http://rc112.vsb.cz/nowakova/materials/ssui/SSUI.pdf>
- [22] WIDROW, B. a M.A. LEHR. 30 years of adaptive neural networks: perceptron, Madaline, and backpropagation. *Proceedings of the IEEE*. 2002, **78**(9): 1415-1442. DOI: 10.1109/5.58323. ISSN 00189219. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=58323>
- [23] IN COOPERATION WITH THE NAVAL POSTGRADUATE SCHOOL, Monterey. *Conference record of the Forty-Fourth Asilomar Conference on Signals, Systems and Computers (ASILOMAR), 2010: 7 - 10 Nov. 2010, Pacific Grove, California*. Piscataway, NJ: IEEE, 2010, s. 1756-1759. ISBN 9781424497218.
- [24] AL., [editors Leon Trilling .. et]. *Recent advances in signal processing , robotics and automation: proceedings of the 8th WSEAS International Conference on Signal Processing, Robotics and Automation, Cambridge, UK, February 21-23, 2009*. S. l.: WSEAS Press, 2009, s. 193-197. ISBN 9789604740543.
- [25] SOCIETY, sponsored by the Institute of Electrical and Electronics Engineers Signal Processing. *Communications sensor array and multichannel signal processing*. Piscataway, NJ: IEEE [u.a.], 1999, s. 2335-2338. ISBN 0780350413.
- [26] ZADEH, L.A. Fuzzy logic = computing with words. *IEEE Transactions on Fuzzy Systems*. 1996, **4**(2): 103-111. DOI: 10.1109/91.493904. ISSN 10636706. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=493904>
- [27] ZADEH, L.A. Fuzzy logic. *Computer*. 1988, **21**(4): 83-93. DOI: 10.1109/2.53. ISSN 0018-9162. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=53>
- [28] ZADEH, L.A. Soft computing and fuzzy logic. *IEEE Software*. 1994, **11**(6): 48-56. DOI: 10.1109/52.329401. ISSN 0740-7459. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=329401>
- [29] ZADEH, Lotfi A. Fuzzy sets. *Information and control*, 1965, **8**.3: 338-353.
- [30] ZADEH, Lotfi A. Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic. *Fuzzy sets and systems*, 1997, **90**.2: 111-127
- [31] JATOTH, R.; ANOOP, SSVKK; PRABHU, Ch Midhun. Biologically inspired evolutionary computing tools for the extraction of fetal electrocardiogram. *WSEAS Trans. Sig. Proc.* **5**, 2009, 106-115.
- [32] TVRDÍK, Jan. *Evolutionary Algorithms*. Ostrava: Ostravská univerzita, 2004. Dostupné také z: http://prf.osu.cz/doktorske_studium/dokumenty/Evolutionary_Algorithms.pdf
- [33] JONES, Gareth. Genetic and Evolutionary Algorithms. *Encyclopedia of Computational Chemistry*. Chichester, UK: John Wiley, 2002. DOI: 10.1002/0470845015.cga004. ISBN 0470845015. Dostupné také z: <http://doi.wiley.com/10.1002/0470845015.cga004>

- [34] POLI's. *Umělá inteligence: Genetické algoritmy* [online]. [cit. 2015-09-23]. Dostupné z: <http://poli.cs.vsb.cz/edu/isy/>
- [35] WERBOS, P.J. Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE* [online]. 1990, **78**(10): 1550-1560 [cit. 2015-09-26]. DOI: 10.1109/5.58337. ISSN 00189219. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=58337>
- [36] BEBIS, G. a M. GEORGIOPOULOS. Feed-forward neural networks. *IEEE Potentials* [online]. 1994, **13**(4): 27-31 [cit. 2015-09-26]. DOI: 10.1109/45.329294. ISSN 0278-6648. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=329294>
- [37] SCHIFFMANN, W.; JOOST, M.; WERNER, R. Optimization of the backpropagation algorithm for training multilayer perceptrons. *Univ. Koblenz, Inst. Physics, Rheinau*, 1992, 3-4.
- [38] JAGANNATH, D.J. a A. Immanuel SELVAKUMAR. Issues and research on foetal electrocardiogram signal elicitation. *Biomedical Signal Processing and Control*. 2014, **10**: 224-244. DOI: 10.1016/j.bspc.2013.11.001. ISSN 17468094. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S1746809413001560>
- [39] JANG, Jyh-Shing Roger. ANFIS: adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions on*, 1993, 23.3: 665-685
- [40] LARMA, Joel D., et al. Intrapartum electronic fetal heart rate monitoring and the identification of metabolic acidosis and hypoxic-ischemic encephalopathy. *American journal of obstetrics and gynecology*, 2007, 197.3: 301. e1-301. e8.
- [41] ÇAYDAŞ, Ulaş; HASÇALIK, Ahmet; EKICI, Sami. An adaptive neuro-fuzzy inference system (ANFIS) model for wire-EDM. *Expert Systems with Applications*, 2009, 36.3: 6135-6139.
- [42] SZÜCSOVÁ, Anikó. *ADAPTÍVNY NEURO-FUZZY INFERENČNÝ SYSTÉM (ANFIS)*. Bratislava, 2007. Diplomová práce. Slovenská technická univerzita v Bratislavě. Vedoucí práce Anna Vašičkaninová.
- [43] VONDRÁK, Ivo. *Neuronové sítě* [online]. Ostrava, 2009, duben 2009 [cit. 2015-11-05]. Dostupné z: http://vondrak.cs.vsb.cz/download/Neuronove_site.pdf. Skriptum. Vysoká škola báňská - Technická univerzita Ostrava.
- [44] CHAKRABORTY, R.C. Fundamentals of Neural Networks: Soft Computing. *My readers info* [online]. Guna: , 2010, 4.th of July.2015 [cit. 2015-11-05]. Dostupné z: http://www.myreaders.info/02-Fundamentals_of_Neural_Network.pdf
- [45] ZELINKA, Ivan. *Umělá inteligence: hrozba nebo naděje?*. 1. vyd. Praha: BEN - technická literatura, 2003. ISBN 80-730-0068-7.
- [46] *Neuronové sítě* [online]. In: . 1. 2011, s. 10 [cit. 2015-11-06]. Dostupné z: <http://www.kiv.zcu.cz/studies/predmety/uir/NS/NN1.pdf>
- [47] POKORNÝ, Miroslav. *Umělá inteligence v modelování a řízení: hrozba nebo naděje?*. 1. vyd. Praha: BEN - technická literatura, 1996. ISBN 80-901-9844-9.

- [48] *Neurónové siete Inžinierský prístup* [online]. Košice, 1998 [cit. 2016-02-20]. Dostupné z: <http://neuron-ai.tuke.sk/cig/source/publications/books/NS1/html/index.html>
- [49] HAMMER, Miloš, Ondřej JANDA a Jakub ERTL. Využití vybraných soft-computingových metod v diagnostice výkonových olejových transformátorů - 1. část. *ElektroRevue*. Brno: VUT Brno, 2012, (No. 3): 14. ISSN 1213-1539.
- [50] CRUZ, Adriano O. *ANFIS: Adaptive Neuro-Fuzzy Inference Systems* [online]. 2015-11-18, : 53 [cit. 2015-11-18]. Dostupné z: <http://equipe.nce.ufrj.br/adriano/fuzzy/transparencias/anfis/anfis.pdf>
- [51] SARANAYA, S. An Efficient Soft-Computing Technique for Extracting Fetal ECG from Maternal ECG. *International Journal for Data Mining Techniques and Applications* [online]. 2012, 2015-11-21, **Vol.1**,(2.): 8 [cit. 2015-11-21]. ISSN 2278-2419. Dostupné z: <http://iirpublications.com>
- [52] SARANAYA, S. a Suja S. PRIYADHARSINI. A Novel Hybrid Soft Computing Technique for Extracting Fetal ECG from Maternal ECG Signal. *International Journal of Computer Applications* [online]. 2010, 2015-11-21, **3**(Num. 8): 7 [cit. 2015-11-21]. ISSN 0975-8887. Dostupné z: <http://www.ijcaonline.org/volume3/number8/pxc3871061.pdf>
- [53] ANUREKHA, R. a A. SIVASANKARI. A Novel Approach for Fetal ECG Extraction –Blood Pressure Patient Using Adaptive Neuro-Fuzzy Inference Systems Trained With PSO. *International Journal of Scientific and Research Publications* [online]. Cuddalore, 2013, **3**(Num. 3): 5 [cit. 2015-11-26]. ISSN 2250-3153.
- [54] ZELINKA, Ivan. *Evoluční výpočetní techniky: principy a aplikace*. 1. vyd. Praha: BEN - technická literatura, 2009, 534 s. ISBN 978-80-7300-218-3.
- [55] ZELINKA, Ivan. *Biologicky inspirované výpočty: Evoluční algoritmy*. Zlín. Vysoká škola Tomáše Bati ve Zlíně.
- [56] SWARNALATHA, R. a D.V. PRASAD. *Maternal ECG Cancellation in Abdominal Signal Using ANFIS and Wavelets*. *Journal of Applied Sciences*[online]. Dubai, 2010, [cit. 2015-11-26]. ISSN 1812-5654.
- [57] BELFORT, Michael A., et al. A Randomized Trial of Intrapartum Fetal ECG ST-Segment Analysis. *New England Journal of Medicine*, 2015, 373.7: 632-641.
- [58] CLIFFORD, Gari D., et al. Non-invasive fetal ECG analysis. *Physiological measurement*, 2014, 35.8: 1521.
- [59] AKAY, Metin. *Nonlinear biomedical signal processing*. New York: IEEE Press, 2001. IEEE Press series in biomedical engineering. ISBN 07-803-6012-5.
- [60] NGUYEN, Hung T. *A first course in fuzzy and neural control*. Boca Raton, FL: Chapman,
- [61] c2003. IEEE Press series in biomedical engineering. ISBN 15-848-8244-1
- [62] Jalaleddine, Sateh, et al. "ECG data compression techniques-a unified approach." *Biomedical Engineering*, IEEE Transactions on 37.4 (1990): 329-343.
- [63] Wen, He, et al. "Comparative Study of Influence of Noise on Power Frequency Estimation of Sine wave Using Interpolation FFT." *Fluctuation and Noise Letters* 13.03 (2014): 1450019.

- [64] MARTINEK, Radek, et al. A novel LabVIEW-based multi-channel non-invasive abdominal maternal-fetal electrocardiogram signal generator. *Physiological Measurement*, 2016, 37.2: 238. Dostupné z <http://iopscience.iop.org/article/10.1088/0967-3334/37/2/238/meta>
- [65] GOLDBERGER AL, AMARAL Lan, GLASS L, HUSDORFF JM, IVANOV PCh, Mark RG, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* **101**(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>]; 2000 (June 13).
- [66] Adaptive Noise Canceling (ANC) Applied to Fetal Electrocardiography. *MathWorks: Products & Services, DSP System Toolbox* [online]. 1994 [cit. 2014-04-17]. Dostupné z: <http://www.mathworks.com/products/dspsystem/examples.html?file=/products/demos/shipping/dsp/adaptncdemo.html>